



**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**

BRNO UNIVERSITY OF TECHNOLOGY

**FAKULTA ELEKTROTECHNIKY  
A KOMUNIKAČNÍCH TECHNOLOGIÍ**

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

**ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ**

DEPARTMENT OF BIOMEDICAL ENGINEERING

**IDENTIFIKACE A VERIFIKACE OSOB POMOCÍ ZÁZNAMU  
EKG**

ECG BASED HUMAN AUTHENTICATION AND IDENTIFICATION

**DIPLOMOVÁ PRÁCE**

MASTER'S THESIS

**AUTOR PRÁCE**

AUTHOR

**Bc. Vojtěch Waloszek**

**VEDOUCÍ PRÁCE**

SUPERVISOR

**Ing. Martin Vítek, Ph.D.**

**BRNO 2021**

# Diplomová práce

magisterský navazující studijní program **Biomedicínské inženýrství a bioinformatika**

Ústav biomedicínského inženýrství

**Student:** Bc. Vojtěch Waloszek

**ID:** 195203

**Ročník:** 2

**Akademický rok:** 2020/21

**NÁZEV TÉMATU:**

## Identifikace a verifikace osob pomocí záznamu EKG

**POKYNY PRO VYPRACOVÁNÍ:**

1) Nastudujte a popište problematiku identifikace a verifikace osob s využitím záznamu EKG. 2) Sestavte vlastní databázi záznamů EKG vhodnou pro identifikaci a verifikaci osob. 3) Navrhněte metodu pro detekci a extrakci příznaků vhodných pro identifikaci a verifikaci osob. Metodu otestujte na vlastních i veřejně dostupných datech. 4) U nalezených příznaků popište jejich biologickou jedinečnost a interpretovatelnost. 5) Vhodné příznaky následně kombinujte za účelem dosažení co největší spolehlivosti identifikace a verifikace osob. 6) Navrženou metodu optimalizujte a proveďte finální testování. 7) Dosažené výsledky diskutujte a porovnejte s jinými autory.

**DOPORUČENÁ LITERATURA:**

[1] BELGACEM, N., et al. ECG Based Human Authentication using Wavelets and Random Forest. International Journal on Cryptography and Information Security. June 2012, Vol. 2, No. 2., pp. 1-11.

[2] SINGH, Y. N., GUPTA, P. ECG to Individual Identification. 2008 IEEE Second International Conference on Biometrics: Theory, Applications and Systems. September 2008, pp. 1-8.

**Termín zadání:** 8.2.2021

**Termín odevzdání:** 21.5.2021

**Vedoucí práce:** Ing. Martin Vítek, Ph.D.

**prof. Ing. Ivo Provazník, Ph.D.**  
předseda rady studijního programu

**UPOZORNĚNÍ:**

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

## Abstrakt

*V posledních letech je zkoumáno využití EKG pro verifikaci a identifikaci osob v biometrických systémech. V této práci je tato možnost rovněž zkoumána a ověřována na databázi ECG ID z PhysioNetu a také na vlastních záznamech měřených pomocí Apple Watch Series 4. Mnohé existující metody již ověřily možnost použití EKG pro biometrii, ale na záznamech pořízených klinickým EKG přístrojem. Tato práce ověřuje možnost využití záznamů EKG pořízených pomocí nositelných zařízení, konkrétně chytrých hodinek. Ze signálu EKG je extrahováno 16 příznaků, které jsou za použití náhodného lesa jako klasifikátoru využity pro verifikaci a identifikaci. Mezi příznaky patří intervaly mezi význačnými body v signálu EKG, potenciálové rozdíly mezi některými body v signálu a variabilita intervalů PR v rámci záznamu. Průměrné výsledky verifikace 14 osob z vlastní databáze dat jsou TRR 96,19 %, TAR 84,25 %.*

## Klíčová slova

*EKG biometrie, verifikace a identifikace, extrakce příznaků, náhodný les, chytré hodinky*

## Abstract

*In the past years, utilization of ECG for verification and identification in biometry is investigated. The topic is investigated in this thesis. Recordings from ECG ID database from PhysioNet and our own ECG recordings recorded using Apple Watch 4 are used for training and testing this method. Many of the existing methods have proven the possibility of using ECG for biometry, however they were using clinical ECG devices. This thesis investigates using recordings from wearable devices, specifically smart watch. 16 features are extracted from ECG recordings and a random forest classifier is used for verification and identification. The features include time intervals between fiducial points, voltage difference between fiducial points and PR intervals variability in a recording. The average performance of verification model of 14 people is TRR 96,19 %, TAR 84,25 %.*

## Keywords

*ECG biometry, verification and identification, feature extraction, random forest, smart watch*

### **Bibliografická citace:**

WALOSZEK, Vojtěch. *Identifikace a verifikace osob pomocí záznamu EKG* [online]. Brno, 2021 [cit. 2021-05-10]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/134425>. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Martin Vítek.

## Prohlášení

*„Prohlašuji, že svou diplomovou práci na téma Identifikace a verifikace osob pomocí záznamu EKG jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.*

*Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.*

V Brně dne 21. května 2021

.....  
podpis autora

## **Poděkování**

*Děkuji vedoucímu diplomové práce Ing. Martinu Vítkovi, Ph.D. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce. Dále děkuji Ing. Radovanu Smíškovi a Ing. Lucii Maršánové za konzultaci kapitoly 7. Také děkuji manželce Elišce za podporu při vypracování této práce.*

V Brně dne: 21. května 2021

.....  
podpis autora

# Obsah

Úvod.....	14
1. Identifikace a verifikace osob .....	15
1.1 Biometrie osob .....	15
1.1.1 Biometrické systémy.....	15
1.1.2 Hodnocení přesnosti verifikačních systémů .....	16
1.1.3 Přehled používaných biometrických charakteristik .....	17
1.1.4 Využití signálu EKG pro biometrii.....	19
2. Elektrická aktivita srdce .....	20
2.1 Elektrofyzilogie srdce .....	20
2.1.1 Akční potenciál .....	20
2.1.2 Převodní systém srdeční .....	21
2.1.3 Šíření elektrického vzruchu srdcem.....	22
2.2 EKG.....	22
2.2.1 Princip měření EKG.....	23
2.2.2 EKG svody.....	23
2.2.3 Tvar signálu EKG .....	24
2.2.4 Frekvenční charakteristika EKG.....	25
2.2.5 Nejčastější typy rušení v EKG.....	26
3. Současné metody EKG biometrie .....	27
3.1 Metoda užívající vlnkovou transformaci a náhodný les .....	27
3.2 První metoda využívající intervaly, amplitudy a úhly .....	27
3.3 Druhá metoda využívající intervaly, amplitudy a úhly .....	28
3.4 Metoda využívající intervaly mezi body srdečního cyklu .....	30
3.5 Metoda využívající analýzu EKG v časové oblasti a SVM .....	31
3.6 Metoda pro verifikaci pomocí rozhodovací neuronové sítě.....	31
3.7 Metoda pro verifikaci porovnáním QRS komplexů.....	31
3.8 Metoda využívající autokorelaci a diskrétní kosinovou transformaci .....	31
3.9 Metoda využívající diskrétní vlnkovou transformaci .....	32
4. Vlastní metoda pro verifikaci osob pomocí záznamů EKG.....	33
4.1 Data použita pro trénování a testování metody .....	33
4.1.1 Databáze záznamů z PhysioNetu .....	33

4.1.2	Databáze vlastních záznamů .....	33
4.2	Extrakce příznaků.....	34
4.2.1	Předzpracování signálu .....	34
4.2.2	Rozměření signálu EKG .....	34
4.2.3	Intervalové příznaky .....	35
4.2.4	Amplitudové příznaky .....	36
4.2.5	Úhlové příznaky .....	36
4.2.6	Příznaky variability intervalů.....	37
4.3	Verifikační a identifikační proces .....	38
4.3.1	Klasifikační strom.....	38
4.3.2	Náhodný les .....	39
5.	Testování a selekce příznaků .....	41
5.1	Grafické hodnocení příznaků .....	41
5.1.1	Intervalové příznaky .....	41
5.1.2	Amplitudové příznaky .....	44
5.1.3	Úhlové příznaky .....	45
5.1.4	Příznaky variability intervalů.....	46
5.2	Redukce příznaků pomocí zpětné selekce.....	48
6.	Trénování modelů a testování úspěšnosti verifikace a identifikace.....	49
6.1	Trénování a testování verifikace osob na databázi z PhysioNetu .....	49
6.1.1	Model 1 .....	49
6.1.2	Model 2 .....	49
6.2	Trénování a testování verifikace osob na rozšířené vlastní databázi záznamů .....	50
6.3	Trénování a testování identifikačních modelů .....	52
6.3.1	Model identifikace 14 osob v populaci 14 osob .....	52
6.3.2	Model identifikace 31 osob v populaci 31 osob .....	53
6.3.3	Model identifikace 14 osob v populaci 100 osob .....	53
6.3.4	Model identifikace 31 osob v populaci 100 osob .....	55
6.3.5	Zhodnocení identifikačních modelů .....	55
6.4	Chyby při detekci význačných bodů v signálu .....	55
6.5	Srovnání dosažených výsledků s jinými autory .....	55
6.5.1	Srovnání výsledků verifikace.....	55



6.5.2	Srovnání výsledků identifikace.....	56
7.	Analýza verifikačního procesu.....	57
7.1	Anatomicko-fyziologická interpretace příznaků.....	57
7.1.1	Intervalové příznaky .....	57
7.1.2	Amplitudové příznaky .....	58
7.1.3	Úhlové příznaky.....	59
7.1.4	Příznaky variability intervalů.....	59
7.2	Hledání spojitosti mezi hodnotami příznaků a věkem a hmotností osob.....	59
7.3	Srovnání důležitosti a přínosu příznaků pro verifikaci osob.....	61
	Závěr .....	66
	Literatura.....	67

## Seznam symbolů a zkratk

### **Zkratky:**

EKG	elektrokardiogram/elektrokardiograf
TAR	true accept rate
FAR	false accept rate
TRR	true reject rate
FRR	false reject rate
SA uzel	sinoatriální uzel
AV uzel	atrioventrikulární uzel
SVM	support vector machine
DCT	discrete cosine transform

## Seznam obrázků

Obrázek 2.1 Akční potenciál pracovního myokardu, převzato z [9] .....	21
Obrázek 2.2 Převodní systém srdeční, převzato z [9].....	22
Obrázek 2.3 Bipolární končetinové Einthovenovy svody, převzato z [8] .....	24
Obrázek 2.4 Typický tvar EKG, převzato z [10] .....	24
Obrázek 2.5 Výkonové spektrum složek EKG, převzato z [11] .....	25
Obrázek 2.6 Nejčastější typy rušení v EKG, převzato z [11] .....	26
Obrázek 4.1 Ukázka rozměření signálu EKG pomocí metody [23] .....	35
Obrázek 4.2 Intervalové a amplitudové příznaky .....	36
Obrázek 4.3 Úhlové příznaky, převzato z [2] .....	37
Obrázek 4.4 Příklad klasifikačního stromu.....	38
Obrázek 5.1 Znázornění variability intervalů QR (vlevo) a RS (vpravo) .....	41
Obrázek 5.2 Znázornění variability intervalů RT (vlevo) a $RT_{\text{offset}}$ (vpravo).....	42
Obrázek 5.3 Znázornění variability intervalů PR (vlevo) a $P_{\text{onset}}R$ (vpravo).....	42
Obrázek 5.4 Znázornění variability intervalů $P_{\text{offset}}R$ (vlevo) a délek vlny P (vpravo) .....	43
Obrázek 5.5 Znázornění variability intervalů PQ (vlevo) a $P_{\text{onset}}Q$ (vpravo) .....	43
Obrázek 5.6 Znázornění variability intervalů $P_{\text{offset}}Q$ (vlevo) a $QT_{\text{offset}}$ (vpravo) ....	43
Obrázek 5.7 Znázornění variability intervalů $ST_{\text{offset}}$ (vlevo) a ST (vpravo).....	44
Obrázek 5.8 Znázornění variability intervalů PT .....	44
Obrázek 5.9 Znázornění variability amplitud RP (vlevo) a RQ (vpravo).....	45
Obrázek 5.10 Znázornění variability amplitud RS (vlevo) a RT (vpravo) .....	45
Obrázek 5.11 Znázornění variability úhlů PQR .....	45
Obrázek 5.12 Znázornění variability úhlů QRS (vlevo) a RST (vpravo) .....	46
Obrázek 5.13 Znázornění variability rozptylu intervalů RR .....	46
Obrázek 5.14 Znázornění variability příznaků variability intervalů QR (vlevo) a RS (vpravo).....	47
Obrázek 5.15 Znázornění variability příznaků variability intervalů RT (vlevo) a $RT_{\text{offset}}$ (vpravo).....	47
Obrázek 5.16 Znázornění variability příznaků variability intervalů PR (vlevo) a $P_{\text{onset}}R$ (vpravo) .....	47

Obrázek 5.17 Znázornění variability příznaků variability intervalů $P_{\text{offset}R}$ .....	48
Obrázek 7.1 Korelační diagram hmotnosti a hodnoty příznaku délky vlny P, modře jsou vyznačeny hodnoty příznaku mužů, červeně žen. Není zde žádná závislost hodnoty příznaku na hmotnosti měřené osoby .....	60
Obrázek 7.2 Korelační diagramy hmotnosti a hodnoty amplitudových příznaků ....	60
Obrázek 7.3 Váha jednotlivých příznaků osob 1201 a 1202 .....	61
Obrázek 7.4 Váha jednotlivých příznaků osob 1207 a 1208 .....	62
Obrázek 7.5 Váha jednotlivých příznaků osob 1205 a 1206 .....	62
Obrázek 7.6 Váha jednotlivých příznaků osob 1212 a 1428 .....	63
Obrázek 7.7 Váha jednotlivých příznaků osob 2200 a 2201 .....	63

## Seznam tabulek

Tabulka 6-1 Počty trénovacích a testovacích záznamů a osob pro jednotlivé verifikační modely .....	50
Tabulka 6-2 Výsledky testování verifikačních modelů pro jednotlivé osoby .....	51
Tabulka 6-3 Výsledky identifikace jednoho z modelů identifikace 14 osob.....	53
Tabulka 6-4 Výsledky identifikace jednoho z modelů identifikace 14 osob i se „zbytkem světa“ .....	54

# Úvod

V dnešní době se biometrické systémy využívají v mnoha oblastech zabezpečení přístupu. Pro biometrii se klasicky využívají modalities jako otisky prstů, skenování duhovky, snímání tváře, rozpoznání hlasu a další. V posledních letech se zkoumá také možnost využití signálu EKG jako biometrické charakteristiky. Na základě zveřejněných článků různých autorů lze vyvodit, že použití signálu EKG pro verifikaci nebo identifikaci osob je skutečně možné. Signál EKG je do určité míry charakteristický pro danou osobu, proměnlivost mnohých charakteristik EKG je v čase nízká. Problematická by ovšem mohla být forma získávání signálu EKG. Ve většině zveřejněných článků se totiž pracuje se záznamy EKG naměřenými pomocí klasických klinických EKG přístrojů. Použití takovýchto přístrojů v reálném biometrickém systému by však bylo nereálné vzhledem k vysoké ceně lékařských EKG přístrojů a k velké složitosti pořizování záznamů. Existuje však také jiný způsob měření záznamů EKG, a to pomocí nositelných zařízení.

Tato práce si klade za cíl ověřit možnost využití signálu EKG jako biometrické charakteristiky pro verifikaci osob za použití chytrých hodinek pro měření záznamů EKG. Konkrétně jsou pro měření záznamů využity chytré hodinky Apple Watch Series 4. Měření záznamu EKG pomocí těchto hodinek se provádí tak, že se k hodinkám nasazeným na jedné ruce přiloží na konkrétní místo prst druhé ruky a drží se 30 sekund. Tato doba je pro biometrii sice pořád poměrně dlouhá, ale složitost měření není vysoká a cena takového senzoru je také nesrovnatelně nižší proti klinickému EKG přístroji. Pokud se má verifikace nebo identifikace pomocí EKG dostat do reálného života, je nutné ji provádět takovým způsobem, aby byla uživatelsky přijatelná.

První kapitola této práce popisuje informace o biometrii jako takové, vysvětluje rozdíl mezi identifikací a verifikací, vyjmenovává využívané biometrické modalities, vysvětluje způsob hodnocení přesnosti verifikace. Druhá kapitola se věnuje elektrokardiografii, elektrofyziologii srdce a signálu EKG jako takovému. Třetí kapitola shrnuje dosud představené metody pro identifikaci nebo verifikaci pomocí EKG za použití různých přístupů.

Ve čtvrté kapitole je již popsána vlastní navržená metoda pro extrakci příznaků ze záznamů EKG a jejich použití pro verifikaci. V páté kapitole jsou navržené příznaky testovány, jednak z hlediska jejich interpersonální variability, a tedy použitelnosti pro rozlišení mezi osobami, a také z hlediska vzájemné podobnosti příznaků. V šesté kapitole je již testována celková funkčnost a úspěšnost metody pro verifikaci a identifikaci osob v různých trénovacích a testovacích scénářích. V sedmé kapitole jsou jednotlivé použité příznaky interpretovány z fyziologického hlediska, dále je analyzována důležitost jednotlivých použitých příznaků a je zkoumána spojitost mezi hodnotami příznaků a známými údaji o jednotlivých osobách.

# 1. IDENTIFIKACE A VERIFIKACE OSOB

I v životě běžného člověka v naší společnosti se vyskytuje mnoho situací, kdy je potřebná jeho identifikace nebo verifikace. Může se jednat o přístup k uživatelskému účtu v různých zařízeních nebo webových aplikacích, přístup do uzavřených prostor, odemknutí elektronického zařízení (například chytrého telefonu) nebo otevření trezoru. Pro všechny tyto situace je společný fakt, že do daného prostoru má přístup pouze vybraná osoba nebo skupina osob a ostatní osoby přístup nemají, nebo se tomu alespoň snažíme zabránit. Správa přístupu do těchto a dalších prostor může být realizována jednoduše mechanickým nebo elektronickým klíčem (čipem), alfanumerickým heslem, číselným kódem nebo gestem. Vyjmenované prostředky správy přístupu umožňují přístup tomu, kdo daný prostředek má nebo zná, nejde však přímo o identifikaci nebo verifikaci osoby. Pro zajištění přístupu jen pro konkrétní osoby se používají biometrické systémy.

Pro správnou orientaci v terminologii je nutné definovat rozdíl mezi identifikací a verifikací. V obou případech jde o rozpoznání dané osoby nějakým systémem. Identifikace je rozpoznávání, zda naměřená data patří některé osobě z databáze způsobem srovnání jedna ku mnoha a také určení které osobě z databáze data patří. Verifikace je určení, zda naměřená data patří jedné konkrétní osobě nebo nepatří způsobem srovnání jedna ku jedné. Biometrické systémy mohou fungovat v identifikačním nebo verifikačním módu rozpoznávání osob, podrobněji jsou tyto módy popsány v kapitole 1.1.1.

## 1.1 Biometrie osob

Biometrie je měření biologických, anatomických, fyziologických nebo behaviorálních charakteristik, které jsou univerzální (všichni lidé by měli mít danou charakteristiku), charakteristické (každé dvě osoby by měly být dostatečně jiné vzhledem k dané charakteristice), permanentní (neměly by se příliš měnit v čase) a měly by být kvantifikovatelné. Pro použití v biometrických systémech by charakteristiky měly být poměrně rychle a přesně měřitelné, lidé by měli být ochotni je každodenně používat a mělo by být obtížné je falsifikovat. Také by systém měření neměl být příliš drahý, nedostupný, a měl by být neškodný pro uživatele. [3]

### 1.1.1 Biometrické systémy

Biometrický systém je ve své podstatě systém pro rozpoznání vzoru. Pracuje tím způsobem, že naměří biometrická data od osoby, provede extrakci příznaků z těchto dat a tyto příznaky porovná se vzorovými příznaky uloženými v databázi.[3]

Biometrické systémy mohou pracovat v těchto dvou módech rozpoznávání osob:

*Verifikační mód* potvrzuje identitu osoby porovnáním právě snímaných biometrických dat se vzorovými biometrickými daty konkrétní osoby uloženými v systémové databázi. Ve verifikačním systému se osoba, která chce být rozpoznána přihlásí ke své identitě, obvykle zadáním osobního identifikačního čísla (PIN), uživatelského jména nebo použitím čipové karty. Systém následně provede porovnání právě snímaných dat a dat příslušících přihlášené osobě uložených v databázi, srovnání dat probíhá způsobem jedna ku jedné. Systém ověřuje, zda se jedná o danou konkrétní osobu nebo ne. Ptáme se například: „Patří tato biometrická data Janu Novákovi?“ Jde

typicky o pozitivní rozpoznávání, cílem je zabránit tomu, aby jednu identitu užívalo více lidí. [3] V této práci je realizován klasifikátor pro biometrický systém ve verifikačním módu tak, že si osoba pomocí chytrých hodinek naměří záznam EKG a systém rozpoznává, zda se jedná o vlastníka těchto hodinek (konkrétní osoba), nebo je to záznam jiné osoby.

*Identifikační mód* rozpoznává osobu tak, že prohledává data všech osob v databázi a hledá shodu. Systém tedy provádí srovnání dat způsobem jedna ku mnoha a zjišťuje identitu dané osoby. Pokud osoba není v databázi, systém osobu nerozpozná. Osoba nemusí dokazovat svoji identitu žádným přihlašованиеm. Ptáme se: „Které z osob v databázi patří tato biometrická data?“ Identifikace je základní součástí v aplikaci negativního rozpoznávání, kde systém určuje, zda daná osoba je tím, kým tvrdí že není. Cílem negativního rozpoznávání je zabránit jedné osobě využívat více identit. Identifikace může být použita i v pozitivním rozpoznávání, kdy se uživatel nemusí přihlásit a je systémem rozpoznán. Biometrie, stejně jako tradiční metody rozpoznání jako hesla, piny, klíče a čipy mohou být použita pro pozitivní rozpoznávání osob, negativní rozpoznávání může být uskutečněno pouze pomocí biometrie v identifikačním módu. [3]

### 1.1.2 Hodnocení přesnosti verifikačních systémů

Při porovnávání úspěšnosti biometrických verifikačních systémů se pro vyčíslení využívají čtyři parametry charakterizující jeho schopnost správně reagovat na vstupní data. Jedná se o procentuální vyjádření schopnosti systému rozpoznat oprávněného uživatele a narušitele a jejich připuštění, respektive nepřipuštění, do chráněného prostoru.

První situace nastává tehdy, kdy oprávněný uživatel je systémem správně rozpoznán a je připuštěn. Číselně se tato situace vyjadřuje buď absolutním počtem pomocí TA – true accept, což je absolutní počet testovacích dat oprávněné osoby správně rozpoznávaných systémem, nebo relativně pomocí TAR – true accept rate, což je míra oprávněně připuštěných případů. TAR vyjadřuje, kolik procent testovacích dat pocházejících od oprávněné osoby bylo systémem správně vyhodnoceno a oprávněná osoba byla v daných případech připuštěna. V ideálním systému se TAR rovná jedné (100 %). Často se místo TAR používá označení senzitivita.

Doplňkem k TAR je FRR – false reject rate neboli míra nesprávně zamítnutých případů. FRR vyjadřuje, kolik procent testovacích dat pocházejících od oprávněné osoby bylo systémem chybně vyhodnoceno a oprávněná osoba nebyla připuštěna. V ideálním systému se FRR rovná nule. Pro TAR a FRR jednoho systému platí, že součet TAR a FRR je vždy roven jedné. FR – false reject je absolutní počet chybných nepřipuštění oprávněné osoby.

Třetí situace nastává tehdy, kdy se do systému chce přihlásit neoprávněný uživatel, systém ho nepozná a narušitel správně není připuštěn. Absolutní počet nepřipuštění narušitele je vyjádřen pomocí TR – true reject. Míra správně zamítnutých případů TRR – true reject rate vyjadřuje, kolik procent testovacích dat pocházejících od neoprávněné osoby bylo systémem správně vyhodnoceno a neoprávněná osoba nebyla v daných případech připuštěna. V ideálním systému se TRR rovná jedné.

Poslední situací je připuštění neoprávněné osoby. FAR – false accept rate vyjadřuje, kolik procent testovacích dat pocházejících od neoprávněné osoby bylo systémem nesprávně vyhodnoceno a neoprávněná osoba byla v daných případech připuštěna. V ideálním systému se FAR rovná nule. Součet FAR a TRR jednoho systému je vždy



roven jedné. FR – false reject udává absolutní počet neoprávněně připuštěných osob v testovacím vzorku dat.

Přesnost (accuracy) vyjadřuje procentuální zastoupení správně vyhodnocených vzorků vůči všem testovacím vzorkům, jak vyjadřuje rovnice (1.1). Doplněk k přesnosti se označuje jako chyba (error).

$$Accuracy = \frac{TA + TR}{TA + FA + TR + FR} \cdot 100 \quad (1.1)$$

Preciznost (precision) vyjadřuje poměr oprávněných připuštěných osob ke všem připuštěným osobám, viz rovnice (1.2).

$$Precision = \frac{TA}{TA + FA} \quad (1.2)$$

Dalším hojně používaným vyhodnocením správnosti systému je F1 skóre. Jedná se o harmonický průměr preciznosti a TAR, viz rovnice (1.3). Toto vyjádření zohledňuje také poměr oprávněných a neoprávněných osob v testovacích datech.

$$F1 = \frac{2 \cdot Precision \cdot TAR}{Precision + TAR} \quad (1.3)$$

### 1.1.3 Přehled používaných biometrických charakteristik

V této kapitole je popsáno několik používaných biometrických charakteristik.

**DNA** (deoxyribonukleová kyselina) obsahuje genetický kód, který je unikátní pro každou osobu, vyjímaje jednovaječná dvojčata. V současné době se využívá pro identifikaci osob ve forenzních aplikacích. Pro ostatní odvětví je tato biometrická charakteristika nepoužitelná ze tří důvodů. Zaprvé je poměrně jednoduché ukrást část DNA. Druhým důvodem je fakt, že v současné době neexistují technologie pro automatické čtení DNA v reálném čase, lze to zatím pouze v laboratorních podmínkách za přítomnosti specializovaného personálu. Třetím důvodem je ochrana soukromí jedinců. DNA obsahuje mimo jiné i informace o predispozici osoby k některým nemocem a panují obavy z diskriminace kvůli znalosti genetické informace, například při přijímání do zaměstnání. [3]

**Tvar ušního boltce** a struktura chrupavkové tkáně ucha je pro jednotlivce charakteristická. Rozpoznávací přístupy využívající tvar boltce srovnávají vzdálenosti výčnělků na vrcholech boltce a význačných bodů. Příznaky získané měřením ucha však nejsou dostatečně význačné pro určení identity osoby. [3] Metody používající neuronové sítě jsou ale schopny dosáhnout velmi dobrých výsledků. Ve článku [4] dosahovaly některé algoritmy využívající neuronové sítě přesnosti přes 99 % při rozpoznávání osob z databáze 77 osob.

**Tvář** je nejběžnější charakteristikou pro rozpoznávání osob lidmi. Rozpoznávání tváře je neobtěžující biometrická metoda, která může mít mnoho podob. Dřívější problémy s detekcí při snímání tváře z jiného než čelního úhlu jsou již v dnešní době překonávány, viz článek [5], přesnost na databázi 65 osob dosahuje více než 98 % i pro obrazy snímány z úhlu. Využívají se 2D nebo i 3D obrazy obličeje.

**Otisk prstu** je velmi diskriminativní biometrická charakteristika, která se hojně využívá v mnoha aplikacích. Každý člověk má jinou skladbu hřebenu a prohlubenin na kůži prstů. TAR a TRR na databázi 100 otisků prstů dosahuje přes 99 % [6]. Otisk prstu je však poměrně zneužitelný. Člověk otisky zanechává na povrchu věcí, kterých se dotknul, a existují způsoby, jak otisk prstu z těchto objektů získat. Proto se dnešní

systémy zabývají i určením, jestli se jedná o živý prst a ne o obraz otisku prstu [6]. V dnešní době není ani problém s cenou skeneru otisku prstů. Metody nejsou ani příliš výpočetně náročné, vyhodnocení systému je rychlé. Otisky prstů jsou vhodné pro identifikaci i verifikaci ve velké populaci.

**Otisk dlaně** pracuje na stejném principu jako otisk prstu. Otisk dlaně vyžaduje větší, a tedy dražší skener. Je však snímána větší plocha, která obsahuje více bodů charakteristických pro daného člověka. [3] Otisk dlaně se také nedá tak jednoduše získat z předmětů, kterých se člověk dotknul, muselo by se jednat o velkou lesklou plochu, které se člověk dotknul celou dlaní.

**Způsob chůze** patří mezi behaviorální charakteristiky. Sám o sobě není příliš charakteristický. Může se obzvlášť v delším časovém horizontu měnit například díky změnám hmotnosti, zraněním apod. Využívá se videosekvence osoby při chůzi, kde se měří pohyb několika kloubů. Tato biometrie je výpočetně náročná. [3]

**Geometrie ruky a prstu** – tvar a velikost dlaně, délky a šířky prstů je jednoduše snímatelna a levná. Je však poměrně málo charakteristická, může se v průběhu času měnit a dalším problémem mohou být náramky a prsteny, které mohou měření některých parametrů znemožnit. [3]

**Termogram tváře a dlaně** je další z možných charakteristik. Měření je bezkontaktní, ale ovlivnitelné teplotou okolních objektů a samotnou teplotou vzduchu, protože ruka se může ochlazovat. Termokamery jsou poměrně drahé, proto se termogramu příliš nevyužívá. [3]

**Duhovka** má specifickou texturu, která se formuje do dvou let života. Duhovka je velmi charakteristická pro rozpoznávání osob, liší se i u jednovaječných dvojčat. Biometrické systémy pro rozpoznávání osob pomocí skenu duhovky jsou rychlé, přesné, bezkontaktní a levné. Je také poměrně snadné detekovat umělé duhovky (kontaktní čočky se zobrazenou cizí duhovkou). [3] Biometrický systém využívající rozpoznání duhovky představený ve článku [7] správně rozpoznal více než 98,5 % testovacích osob v databázích několika stovek až tisíce lidí. Biometrie duhovky je použitelná i pro velké populace osob.

**Sken sítnice** se provádí tak, že se osoba podívá do kukátka a fixuje konkrétní bod, aby kamera mohla snímat konkrétní oblast sítnice. Na sítnici se zkoumá její bohatá síť cév, která je pro každého charakteristická. Sítnice se považuje za jednu z nejbezpečnějších biometrických charakteristik, protože není snadné změnit nebo replikovat tuto síť cév. Nutnost přiložení oka ke kukátku a zaostřit na konkrétní místo odráží uživatele od použití této biometrie. Sken sítnice také může odhalit některá onemocnění, což dále působí proti širšímu využití této biometrie. [3]

**Způsob psaní na klávesnici** je málo charakteristická behaviorální biometrie. Může ale pomoci při verifikaci pomocí hesla. Měřenou osobu toto měření nijak neobtěžuje, protože by heslo stejně musela napsat. [3]

**Podpis** je charakteristika, která je využívána pro ve vládních, občanských i komerčních sektorech. Jedná se o behaviorální charakteristiku, která se mění v čase, je ovlivněna fyzickými a emočními podmínkami. U některých lidí je jiný každý podpis, i když se osoba podepíše dvakrát po sobě. Podpis může být poměrně lehce zneužit, protože se dá podle vzoru naučit.

**Hlas** je kombinace fyziologické a behaviorální biometrické charakteristiky. Je ovlivněn tvarem a velikostí hlasivek, úst, nosních dutin, jazyka a rtů. Dále věkem, zdravotním a emočním stavem atd. Hlas není příliš biometricky charakteristický, nebyl by vhodný pro biometrické rozpoznávání ve velké populaci. [3]

Pro zvýšení úspěšnosti biometrických systémů se často provádí kombinace několika biometrických charakteristik do jednoho systému. Tyto systémy se označují jako multimodální.

### 1.1.4 Využití signálu EKG pro biometrii

V posledních asi dvaceti letech se zkoumá možné využití EKG v biometrických systémech. Signál EKG by bylo velmi těžké zreprodukovat pro neoprávněný přístup do systému. Použití signálu EKG v biometrii je možné za předpokladu, že je pro jednotlivce alespoň do určité míry charakteristický. Tento předpoklad se v publikovaných metodách potvrzuje. EKG je tedy možné pro biometrii použít. Otázka je, do jaké míry je EKG možné použít samostatně bez dalších biometrických modalit. Tato otázka souvisí s chybou, jakou jednotlivé systémy mají a jakou míru zabezpečení vyžadujeme. V budoucích reálných biometrických systémech předpokládáme spíše využití EKG jako doplňkové modality k jiné hlavní modalitě (např. otisku prstu nebo skenu duhovky) pro zvýšení bezpečnosti systému snížením možnosti falsifikace.

Mezi výhody verifikačních systémů využívajících EKG patří například fakt, že tuto biometrickou charakteristiku mají pouze živé osoby, signál EKG je obtížné napodobit. [1]

V mnoha níže popsaných metodách byly využívány signály EKG naměřené standartními lékařskými EKG přístroji, ať už dvanáctisvodové, třísvodové, nebo byl využit pouze jeden svod. Tyto EKG přístroje jsou velmi drahé a akvizice pomocí těchto přístrojů vyžaduje určitá pravidla, například se typicky používají svorkové končetinové elektrody, kdy se mezi kůži a elektrodu aplikuje kontaktní gel. Metoda navržená v této práci pracuje se signály EKG naměřenými pomocí chytrých hodinek. Tento způsob měření je zcela nenáročný a použité chytré hodinky nejsou zdaleka tak drahé jako běžné lékařské EKG přístroje. Využití chytrých hodinek pro měření signálu EKG jako biometrické modalit je i uživatelsky přijatelné a pravděpodobně se v blízké budoucnosti stane součástí reálných systémů.

Pro naměření signálu EKG pomocí chytrých hodinek je potřebné mít hodinky nasazené na ruce a prst druhé ruky po dobu měření (v případě Apple Watch je to 30 s) nehybně držet na elektrodě umístěné na čelní nebo boční straně hodinek. 30 s je pro každodenní verifikaci poměrně dlouhá doba. Doba pro naměření signálu však vždy bude alespoň několik jednotek až desítek sekund, což je v porovnání s jinými systémy velmi dlouhá doba. Zde pak stojí za zvážení, zda je vyšší bezpečnost biometrického systému důležitější než pohodlí uživatele. Dalším aspektem měření signálu pomocí chytrých hodinek je fakt, že měření signálu není nutné provádět každý den (například při vstupu do nějakých prostor), ale pouze pokaždé, když si uživatel sundá, respektive znovu nasadí hodinky a chce provést verifikaci. Lze totiž detekovat, zda má osoba hodinky nasazené, nebo si je sundala. Pokud by se v budoucnu vyráběly vodotěsné chytré hodinky a uživatel by nevyžadoval jejich sundání na dobu spánku (což některé osoby nevyžadují i vzhledem k tomu, že chytré hodinky využívají ke sledování svého spánku), mohlo by k ověřování identity docházet i poměrně málo často a delší doba měření by tak uživatele tolik neobtěžovala.

Signál EKG je tedy pro biometrii využitelný. Tato práce si klade za cíl ověřit možnost využití signálů EKG naměřených pomocí chytrých hodinek v biometrických verifikačních systémech tím, že kombinací různých metod pro extrakci příznaků a vlastním přínosem vytvoří vlastní verifikační algoritmus a otestuje jeho úspěšnost.

## 2. ELEKTRICKÁ AKTIVITA SRDCE

Pro správnou mechanickou činnost srdce je nutné, aby byly stahy jednotlivých buněk srdeční svaloviny koordinované, aby na sebe vhodně navazovaly, aby byla mechanická práce efektivní a mohlo docházet k adekvátnímu pumpování krve do krevního oběhu. Srdeční aktivita musí odpovídat aktuálním potřebám organismu při různé zátěži, je nutné průběžně měnit rychlost a sílu srdečních stahů, a přitom by mechanická energie měla být využita efektivně. Kapitola 2.1 se věnuje elektrofyzilogii srdce a popisuje, jak vzniká, jak vypadá a jak se šíří elektrický signál, který řídí následnou mechanickou činnost srdečních buněk. Kapitola 2.2 se pak věnuje tomu, jak lze elektrickou aktivitu srdce měřit na povrchu těla a jaké jsou hlavní časové a frekvenční charakteristiky naměřeného elektrického signálu.

### 2.1 Elektrofyzilogie srdce


Srdeční svalovina se skládá ze dvou typů buněk. Buňky prvního typu vytvářejí elektrické impulzy a rozvádějí je, buňky druhého typu odpovídají na impulzy mechanickou kontrakcí. Buňky prvního typu tvoří převodní systém srdeční, buňky druhého typu se nazývají pracovní svalovina srdce, pracovní myokard. Je nutno dodat, že oba typy buněk jsou schopné převodu elektrického signálu, ale buňky převodního systému jsou uzpůsobené k rychlému převodu signálu. Srdeční buňky v síních a komorách (zvláště v síních a zvláště v komorách) jsou vzájemně funkčně propojeny, tvoří tzv. funkční syncytium. Podnět, který vznikne někde v síních vede ke smrštění obou síní, tzv. kontrakce „vše nebo nic“, podobně to platí i v komorách. [8]

Buňky kosterní svaloviny se smršťují až tehdy, když jsou aktivovány elektrickým impulzem přicházejícím zvenčí pomocí nervového systému. Srdeční buňky mají schopnost vytvářet elektrický impuls samostatně, tedy dochází ke spontánní aktivaci i bez vnějšího signálu. Tato vlastnost se nazývá srdeční automacie nebo autonomie srdce. Tuto vlastnost mají všechny buňky převodního systému, přičemž některé jsou schopny vytvářet elektrický impuls častěji, pravidelně s určitou frekvencí. Nejvyšší frekvenci vytváření elektrických impulsů mají za normálních podmínek buňky v sinusovém (SA) uzlu, SA uzel je primární fyziologický pacemaker srdce, v případě jeho poškození přebírá roli pacemakeru atrioventrikulární (AV) uzel, který vytváří elektrické vzruchy s nižší frekvencí, takže za normálních podmínek impuls pouze převádí. Srdeční rytmus v SA uzlu je ovlivňován také pomocí nervů (nervus vagus a sympatikus), takže srdeční frekvence je řízena i centrálně na základě potřeb organismu. [8]

#### 2.1.1 Akční potenciál

Elektrický impuls, jinak také nazývaný jako akční potenciál, má v srdečních buňkách oproti neuronům a kosterním svalům jiný časový průběh, je vyobrazen na obr. 2.1. V první fázi po podráždění dochází k rychlé depolarizaci neboli vyrovnání elektrického potenciálu mezi vnitřkem buňky a okolním prostředím pomocí otevření rychlých sodíkových a draslíkových iontových kanálů. Po depolarizaci dochází k mechanické kontrakci srdeční buňky. Následuje fáze plató, kdy dochází jen k pomalé změně potenciálu uvnitř buňky. Ve fázi plató nemůže dojít k dalšímu podráždění, což umožňuje synchronizaci srdeční činnosti a buzení s potřebnou fyziologickou frekvencí. Následuje


fáze repolarizace, kdy dochází k opětovnému vytvoření napětí mezi vnitřním prostředím buňky a jejím okolím, v průběhu této fáze může dojít k novému podráždění buňky. Buňky převodního systému mají podobný časový průběh akčního potenciálu. Rozdíl je v klidové fázi, kdy u buněk převodního systému dochází k pomalé depolarizaci. Když tato pomalá depolarizace překročí určitý práh, dojde ke vzniku akčního potenciálu, tedy k rychlé depolarizaci, fázi plató a repolarizaci. [9]



Obrázek 2.1 Akční potenciál pracovního myokardu, převzato z [9]

### 2.1.2 Převodní systém srdeční

Na obrázku 2.2 je schematicky znázorněn převodní systém srdeční. Za fyziologických podmínek vzniká elektrický podnět v SA uzlu, frekvence je dána buď samotnými buňkami SA uzlu nebo je snižována působením nervu vagu nebo zvyšována působením sympatiku. Sympatikus zvyšuje také sílu stahu buněk pracovního myokardu a zrychluje převod impulsu v převodním systému. Z SA uzlu se podráždění šíří svalovinou síní (buněkami pracovního myokardu) rychlostí 0,8-1 m/s na AV uzel. V AV uzlu je vedení vzruchu pomalé (rychlost 0,05 m/s), vytváří se tak zdržení mezi kontrakcí síní a kontrakcí komor, tak aby došlo k efektivnímu pumpování krve. Z AV uzlu vzruch pokračuje rychlostí 1-1,5 m/s Hisovým svazkem a Tawarovými raménky k srdečnímu hrotu, odkud je vzruch Purkyňovými vlákny velmi rychle (rychlostí 3-3,5 m/s) rozváděn směrem k srdeční bázi, od vnitřní vrstvy myokardu k vnější. Mezi síněmi a komorami se nachází nevodivé vazivový skelet, který zabraňuje nechtěnému přechodu impulsu mezi síněmi a komorami. Jediné místo, kudy může impuls do komor projít je Hisův svazek, který navazuje na AV uzel. [8], [9]



Obrázek 2.2 Převodní systém srdeční, převzato z [9]

### 2.1.3 Šíření elektrického vzruchu srdcem

Při postupu elektrického impulsu srdcem dochází postupně nejprve k depolarizaci a po určitém čase k repolarizaci buněk. Při prostorovém postupu impulsu hovoříme o depolarizační vlně. Cytoplazma buněk v klidu má záporný potenciál, okolí buněk má kladný potenciál. Při depolarizaci dochází k přesunu kladného náboje do buněk, přičemž v prostředí kolem buněk dočasně vzniká záporný náboj. Tento lokální dočasně snížený náboj snižuje napětí mezi okolím buněk a blízkými sousedními buňkami a dojde tak k depolarizaci dalších buněk v okolí. Buňky, kde před chvílí došlo k depolarizaci jsou ve fázi plató, takže se depolarizují buňky pouze v dopředném směru šíření.

Mezi čelem depolarizační vlny, kde je prostředí mimo buňky záporně nabitě, a dosud nepolarizovanými buňkami vzniká potenciálový rozdíl, který se dá na elementárním objemu charakterizovat pomocí elektrického dipólového momentu, který má stejný směr jako šířící se depolarizační vlna. Pokud se podíváme na srdce jako celek, můžeme provést vektorový součet elementárních elektrických dipólových momentů a tím získáme elektrický srdeční vektor. Tento vektor udává okamžitou celkovou orientaci depolarizace srdce. V případě repolarizace má tento vektor opačný směr, než je směr postupující repolarizační vlny. Elektrický srdeční vektor tedy ukazuje v každém okamžiku směr postupu depolarizace nebo repolarizace. Při měření EKG dochází k měření časového průběhu tohoto elektrického srdečního vektoru.

## 2.2 EKG

Zkratka EKG se využívá jednak pro elektrokardiograf, tedy přístroj pro snímání elektrického signálu ze srdce, nebo pro elektrokardiogram, tedy samotný elektrický signál ze srdce. V této práci je zkratkou EKG myšlen vždy elektrický signál ze srdce, pokud není výslovně uvedeno jinak.

## 2.2.1 Princip měření EKG


EKG je elektrický signál, jedná se o elektrické napětí mezi určitými body na těle, které vzniká při elektrické aktivaci srdce, toto elektrické napětí je proměnné v čase. Na některá místa na kůži se umístí elektroda, která je s kůží vodivě spojena. Elektroda měří elektrický potenciál daného místa na kůži. Pokud jsou na těle umístěny dvě elektrody, můžeme měřit napětí mezi elektrodami. Při konkrétním umístění elektrod (například na levé a pravé ruce) hovoříme o svodu EKG (například svod I). EKG svod je elektrický obraz srdce při konkrétním umístění elektrod. [8] EKG se někdy měří i jinde než na kůži, elektrody se mohou při operacích nebo katetrizaci umisťovat i přímo na srdce.

## 2.2.2 EKG svody

V medicíně se běžně používá dvanáctisvodové měření EKG, kdy se na pacienta umístí devět měřících elektrod a měří se napětí mezi určitými dvojicemi elektrod, nebo se měří napětí mezi jednou elektrodou a průměrem jiných elektrod. Jedná se konkrétně o tři bipolární končetinové svody I, II a III, vždy mezi dvěma elektrodami umístěnými na končetinách (viz obr. 2.3), dále tři unipolární končetinové Goldbergerovy svody, napětí se měří vždy mezi jednou končetinou a průměrnou hodnotou zbývajících dvou končetin, a nakonec šest hrudních svodů, vždy mezi jednou z šesti hrudních elektrod a průměrnou hodnotou tří končetinových elektrod. Každý svod se na srdce „dívá“ z jiného úhlu nebo směru, proto má každý svod unikátní tvar. Na obrázku 2.3 v části 2 je znázorněn Einthovenův trojúhelník, který zobrazuje tři bipolární končetinové svody. Elektrické napětí naměřené v určitém svodu odpovídá průmětu elektrického srdečního vektoru (znázorněného červenou šipkou) do roviny daného svodu (znázorněno fialovými šipkami). Znázornění kladné a záporné elektrody u každého svodu znamená, že při výpočtu napětí mezi těmito elektrodami se odečítá od potenciálu kladné elektrody potenciál záporné elektrody. Kdyby se zaměnilo pořadí, byl by daný svod otočený (inverzní). [8]


V této práci se pracuje pouze s jednosvodovým EKG, napětí se měří mezi horními končetinami. Jedná se tedy o svod I.





Obrázek 2.3 Bipolární končetinové Einthovenovy svody, převzato z [8]

### 2.2.3 Tvar signálu EKG



Obrázek 2.4 Typický tvar EKG, převzato z [10]

Typický tvar signálu EKG je vyobrazen na obr. 2.4, přibližně takový tvar mají svody I a II, ostatní svody obsahují stejné části, které ale mohou mít jinou polaritu. Typický srdeční cyklus v EKG začíná vlnou P. Vlna P odpovídá depolarizaci síní, tedy začíná depolarizací v SA uzlu a šíření depolarizační vlny svalovinou síní. Vlna P má délku trvání 80-100 ms. Po skončení vlny P následuje izoelektrický úsek PQ, kdy je vzruch pomalu veden atrioventrikulárním uzlem, vzniká tak zpoždění mezi depolarizací síní a depolarizací komor. Typická délka úseku PQ je 80-100 ms. Celková doba od začátku vlny P po začátek QRS komplexu nesmí přesáhnout 200 ms. [10]




Následuje komplex QRS, který odpovídá depolarizaci svaloviny komor, je to nejvýraznější část celého EKG signálu. Kmit Q je první negativní kmit komplexu QRS, který však nemusí být přítomen. Kmit R je první pozitivní kmit komplexu QRS, je vždy přítomen. Kmit S je první negativní kmit za kmitem R. Doba trvání komplexu QRS je typicky 60-100 ms. Pozitivní kmit odpovídá šíření depolarizační vlny svalovinou komor od AV uzlu směrem k srdečnímu hrotu, po něm následující záporný kmit odpovídá šíření depolarizační vlny od srdečního hrotu směrem k srdeční bázi. V průběhu komplexu QRS dochází také k repolarizaci svaloviny síní, tato elektrická aktivita je však nízká v porovnání s depolarizací komor, a proto se nedá nijak pozorovat. [10]

Po komplexu QRS přichází izoelektrický úsek ST, odpovídá fázi plató svalových buněk srdečních komor. Následuje vlna T, která odpovídá postupné repolarizaci myokardu komor. Repolarizační vlna má opačný směr než depolarizační vlna, ale má také opačnou polaritu, a proto je ve svodech I a II pozitivní. Interval mezi začátkem komplexu QRS a koncem vlny T odpovídá době elektrické aktivity komor a je závislý na tepové frekvenci, při 72 tepech za minutu trvá 350-400 ms. Za vlnou T se někdy může objevit nízká vlna U, která se objevuje spíše u mladších jedinců a je pravděpodobně výrazem pomalejší repolarizace Purkyňových vláken, její význam je však nejasný. [10]

## 2.2.4 Frekvenční charakteristika EKG


Většina energie signálu EKG se nachází ve frekvenčním rozsahu 0-100 Hz, v moderních studiích se zkoumají i vysokofrekvenční složky EKG až do frekvence 500 Hz. Na obrázku 2.5 je znázorněno výkonové spektrum jednotlivých hlavních složek EKG, neboli na kterých frekvencích je zastoupeno nejvíce energie signálu. Hlavní energie signálu EKG se tedy z frekvenčního hlediska nachází v pásmu 0-40 Hz.



Obrázek 2.5 Výkonové spektrum složek EKG, převzato z [11]

## 2.2.5 Nejčastější typy rušení v EKG

Kromě samotné srdeční aktivity se v EKG projevují také různé typy rušení. Nejčastější typy rušení jsou vyobrazeny na obr. 2.6. V části a) vidíme kolísání nulové izoliny, které se běžně označuje jako drift. Je to nízkofrekvenční rušení s frekvencí přibližně do 1 Hz, může být způsobeno zejména dýchacími pohyby. Toto nízkofrekvenční rušení lze snadno odfiltrovat, ale filtrací může dojít i ke změně užitečných složek signálu. V části b) vidíme elektrodové pohybové artefakty, tedy výrazné výkyvy napětí způsobené pohybem elektrody na kůži. Tento typ rušení má frekvenční rozsah přibližně 1-10 Hz, to znamená že nelze běžně odfiltrovat bez výrazného poškození užitečných složek signálu. Při měření EKG pomocí chytrých hodinek může k tomuto artefaktu často docházet, protože elektrody nejsou pevně přilepeny a zejména elektroda držená prstem se vůči kůži prstu může velmi často a výrazně pohybovat. V části c) je vyobrazeno svalové rušení, tedy EMG signál vytvořený aktivací kosterních svalů. Toto rušení má široké frekvenční pásmo 5-500 Hz, zasahuje takřka celé užitečné pásmo signálu EKG, úroveň rušení závisí na síle aktivace svalů a na poloze vůči měřenému svodu, v našem případě se projeví zejména aktivita rukou a hrudních svalů. V části d) je zobrazen jev proměnlivé amplitudy QRS komplexu (v tomto případě kmitu S) v závislosti na dýchání, frekvence těchto změn odpovídá dýchací frekvenci, tedy přibližně 0,25 Hz. Posledním běžným typem rušení je síťové rušení vzniklé vlivem napětí v elektrické rozvodné síti, napětí se může naindukovat na vodičích elektrod v případě blízkosti ze sítě elektricky napájeného přístroje v blízkosti měřené osoby. Frekvence síťového rušení je v Evropě 50 Hz, v USA 60 Hz. [11]



Obrázek 2.6 Nejčastější typy rušení v EKG, převzato z [11]

### 3. SOUČASNÉ METODY EKG BIOMETRIE

V této kapitole je představeno široké spektrum existujících zveřejněných metod rozpoznání osob s využitím signálu EKG. Metody by se daly rozdělit do dvou kategorií: a) metody využívající rozměření signálu, které využívají časové, amplitudové, úhlové, dynamické (např. RR interval) příznaky a příznaky měřící plochy, b) metody bez rozměrování, kdy není potřeba detekovat žádný bod v signálu nebo je potřeba detekovat pouze kmit R, což je nejsnadněji detekovatelný bod v signálu EKG (například autokorelace, vlnkové transformace, diskretní kosinová transformace, autokorelace) [12].

#### 3.1 Metoda užívající vlnkovou transformaci a náhodný les

V roce 2012 vyšel článek [1], kde je popsána metoda pro verifikaci osob pomocí EKG využívající vlnkovou transformaci a náhodný les. Autoři využívali záznamy EKG ze čtyř veřejně dostupných databází naměřených na konvenčním dvanáctisvodovém EKG přístroji (přičemž pro trénování a testování využívali pouze svod II) a také vytvořili vlastní databázi o dvaceti lidech měřeními jednoho svodu pomocí válcových elektrod držených v dlaních (to odpovídá konvenčnímu EKG svodu I), vzorkovací frekvence 250 Hz, pro každou osobu byly naměřeny čtyři dvouminutové záznamy, kdy první minuta byla vždy použita jako trénovací záznam a druhá minuta jako testovací záznam. Záznamy měřené pomocí suchých elektrod držených v ruce jsou náchylnější na rušení – jakýkoli pohyb ruky se projeví v EKG záznamu jako kolísání izoliny nebo svalové rušení. [1]


Signály jsou v rámci předzpracování filtrovány pásmovou propustí s mezními frekvencemi 1-40 Hz pro odstranění stejnosměrné složky, kolísání izoliny, síťového a vysokofrekvenčního rušení. Dále je provedena detekce kmitů R, aby bylo možné provést průměrování jednotlivých srdečních cyklů, takže z každého signálu (respektive minuty signálu) je vytvořen jeden průměrný srdeční cyklus délky 192 vzorků. Zprůměrněný cyklus má vysoký poměr signál šum. Následně se provede diskretní vlnková transformace stupně 5 s použitím vlnky db3. Vlnkové koeficienty jsou pak použity jako příznaky. Pro klasifikaci je použit náhodný les o 15-20 stromech. [1]

Výsledky testování verifikace 80 zdravých osob byly FAR = 0,6 %, FRR = 0,58 % [1]. Tím, že bylo pro trénování a testování použito stejného signálu (rozděleného na polovinu) mohou být výsledky uměle lepší. Při reálném biometrickém ověřování by došlo k trénovacímu a testovacímu měření zvlášť, přičemž by se signály pravděpodobně více lišily.

#### 3.2 První metoda využívající intervaly, amplitudy a úhly

Lena Biel a kolektiv představili v roce 2001 metodu [13] pro identifikaci osob. Autoři využívali 85 dvanáctisvodových záznamů od 20 osob. Z každého svodu bylo extrahováno 30 příznaků (celkem 360), jedná se o intervaly mezi jednotlivými částmi cyklu, amplitudové příznaky, plocha komplexu QRS, úhel ST segmentu, tvar vlny T, přítomnost vrubu v R vlně. Bylo prozkoumáno použití zvlášť jen hrudních a končetinových svodů. Výsledky byly podobné, takže se dále využívaly pouze končetinové svody, protože jsou jednodušší pro naměření a nezávislé na přesném umístění elektrody, které mohou být umístěny kdekoli na ruce. Následně byl vybrán pouze svod 1, aby pro měření stačilo umístit pouze dvě elektrody na ruce + jednu zemnicí elektrodu, zbylo tak jen 30 příznaků.

Počet příznaků byl následně zredukován pomocí korelační matice na 12 (byly odstraněny vysoce korelované příznaky). Po další redukci zůstalo 10 příznaků, které jsou zobrazeny na obr. 3.1. [13]



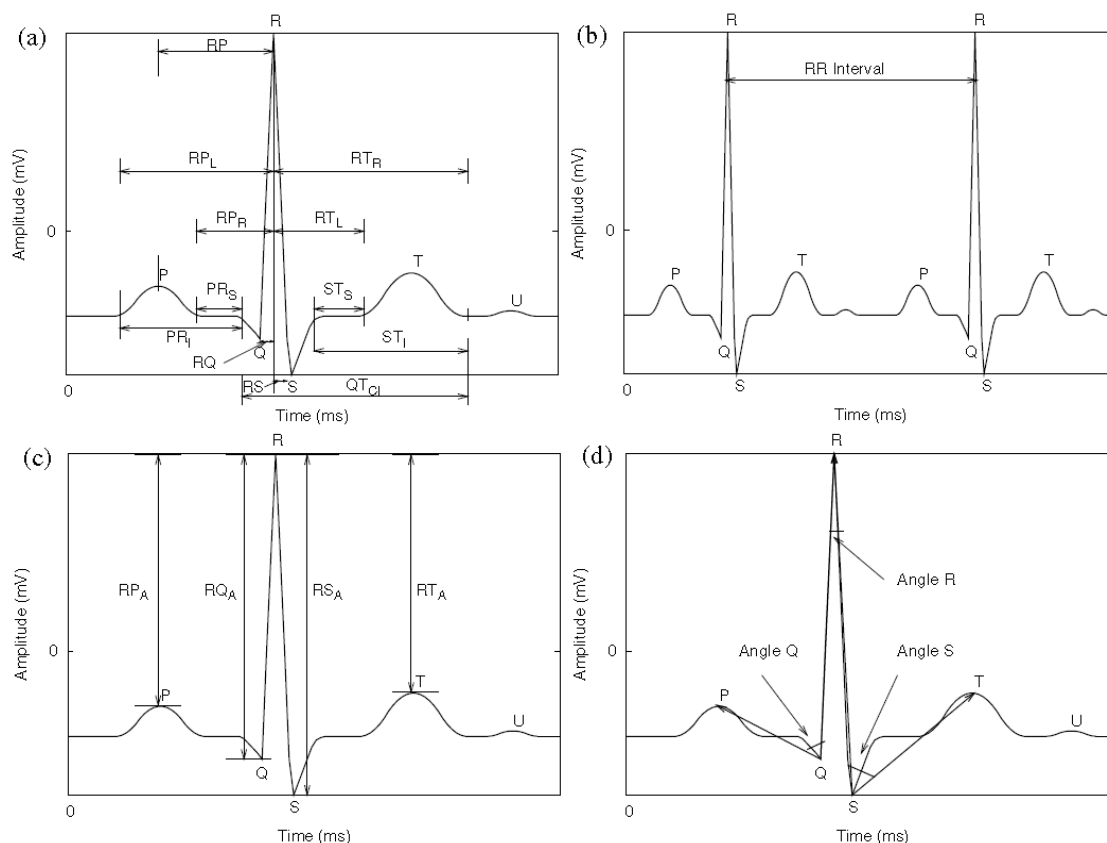
**Obrázek 3.1: 10 příznaků využitých pro další zpracování. Převzato z [13]**

Pro identifikaci osob je použit model SIMCA, který hledá podobnosti mezi testovacími objekty ve třídách. Hlavním krokem při SIMCA modelování je analýza hlavních komponent (PCA) pro každou třídu (osobu). Výsledek testování je přesnost 95 %. [13]

### 3.3 Druhá metoda využívající intervaly, amplitudy a úhly

Tato metoda popsaná ve článku [2] užívá jednosvodový signál EKG. Nejprve je v rámci předzpracování lineárním filtrem odstraněn nízkofrekvenční a vysokofrekvenční šum. Poté je rozměřen komplex QRS s použitím metody představené ve článku [14] s drobnými úpravami, je využita analýza strmosti, amplitudy a šířky vln EKG. Na základě časové derivace a adaptivního prahování jsou rozměřeny vlny P a T. Po rozměření jsou v signálu označeny polohy význačných bodů (začátek, vrchol a konec vlny P, začátek komplexu QRS, kmity Q, R, S, vrchol a konec vlny T). Z polohy těchto bodů je vypočítáno 19 příznaků. Jedná se o 12 intervalů mezi jednotlivými body v rámci jednoho cyklu (obr. 3.2 a), RR interval (mezi R vlnami sousedních srdečních cyklů, viz obr. 3.2 b). Další 4 příznaky jsou vypočítány jako napěťový rozdíl kmitu R a kmitů Q, S, vrcholu vlny P a vrcholu vlny T (obr. 3.2 c). Poslední tři příznaky jsou vypočteny jako úhel mezi jednotlivými body (obr. 3.2 d). [2]

Srdeční frekvence se neustále mění v důsledku změn tlaku uvnitř srdce a změny objemu komor. Změna srdeční frekvence také ovlivňuje dobu trvání vlny P, interval PR a interval QT. Proto jsou všechny intervalové příznaky, ve kterých vystupuje některý bod vln P a T jsou normalizované (podělené) délkou daného cyklu. Ostatní příznaky jsou vůči změnám tepové frekvence invariantní. [2]



**Obrázek 3.2 Grafické znázornění příznaků extrahovaných ze signálu EKG.**


**a) Intervals v rámci jednoho cyklu, b) interval mezi dvěma cykly, c) napět'ové rozdíly mezi kmitem R a jiným bodem v rámci jednoho cyklu, d) úhly mezi body v rámci jednoho cyklu. Převzato z [2].**

Identifikační model je založen na srovnávání podle vzoru a adaptivním prahování. Dva záznamy EKG jsou považovány za stejné, pokud jsou jejich příznaky podobné. Jinak řečeno, pokud je rozdíl mezi korespondujícími komponenty příznakového vektoru je nižší, než je určeno prahem, jsou tyto záznamy považovány za stejné. [2]

Metoda byla trénována a testována na záznamech pocházejících od 25 osob. Jedná se o identifikační model, tedy dochází k porovnávání zkoumaného záznamu se všemi 25 vzory uloženými v databázi. Následně se určuje, zda bude zkoumaná osoba připuštěna nebo nepřipuštěna. Pro testování negativní identifikace jsou použity další záznamy z jiné databáze. Výsledkem testování je přesnost (accuracy) 98 %, s tím, že na nastavení prahu záleželo, zda 2 % chybných výsledků bude neoprávněně připuštěných (FAR) nebo nesprávně zamítnutých (FRR) testovacích vzorků. [2]

### 3.4 Metoda využívající intervaly mezi body srdečního cyklu

Steven Israel a kolektiv představil metodu [15], ve které zkoumá použitelnost EKG pro biometrii, závislost příznaků na umístění elektrod a na úrovni stresu. Metoda byla testována na záznamech od 29 osob, celkem bylo vytvořeno 41 souborů záznamů, kdy každý soubor obsahuje sedm dvouminutových záznamů, přičemž každý z nich je nasnímán v určitém stresovém rozpoložení. Signály jsou vždy předzpracovány pásmovou propustí s mezními frekvencemi 2 a 40 Hz. Následně jsou v signálu detekovány význačné body, které jsou vyobrazeny na obrázku 3.3. Následně jsou vypočítány časové intervaly mezi jednotlivými body, celkově 15 intervalů, které jsou použity jako příznaky. Časové intervaly mezi body jsou normalizovány (poděleny délkou cyklu, tedy intervalem  $L'T'$ ), aby se eliminoval vliv proměnlivé tepové frekvence, po normalizaci jsou intervaly jedné osoby přibližně nezávislé na tepové frekvenci. Ze všech 15 příznaků je po korelační analýze vybráno pouze 12 příznaků pro další analýzu. Použitelnost EKG pro biometrii byla prokázána. [15]



**Obrázek 3.3 Význačné body signálu, převzato z [15] a upraveno**

Pro zjištění závislosti správnosti identifikace na poloze elektrod byl proveden experiment, kdy pro trénování klasifikační funkce byly použity záznamy při umístění elektrod u základny krku a pro testování záznamy při umístění elektrod v pátém mezižebním prostoru. Správnost identifikace jednotlivých srdečních cyklů byla okolo 80 %, identifikace jednotlivců podle celého záznamu pak měla 100 % úspěšnost. [15]

Pro zjištění závislosti správnosti identifikace na různé úrovni stresu byl proveden experiment, kdy byly záznamy naměřeny v klidových podmínkách a ve stresových situacích (například řízení auta na trenažéru, hlasité čtení, matematické operace). Ve stresových situacích je vyšší tepová frekvence, vyšší svalový šum a variance v amplitudě potenciálu. Cílem bylo dokázat nezávislost příznaků na těchto změnách. Experiment byl proveden tak, že bylo provedeno trénování a testování nejprve ve stejné úrovni stresu a také trénování v jedné a testování ve druhé úrovni stresu. Při trénování a testování ve stejné úrovni stresu byla správnost identifikace podle jednotlivých srdečních cyklů kolem 80 %, identifikace podle celého záznamu 97 %. Při trénování a testování v různých úrovních stresu byla správnost identifikace podle jednotlivých srdečních cyklů kolem 65 %, identifikace podle celého záznamu 98 %. Tím bylo dokázáno, že příznaky jsou nezávislé na úrovni stresu. Záznamy pořízené při řízení

na trenažeru obsahovaly vysokou úroveň svalového šumu, který není navrženým předzpracováním odstraněn, takže tyto záznamy vykazovaly větší nepřesnosti. [15]

### **3.5 Metoda využívající analýzu EKG v časové oblasti a SVM**

Metoda představená v roce 2019 ve článku [16] využívá jednosvodový záznam EKG se vzorkovací frekvencí 100 Hz. Signál je předzpracován odstraněním stejnosměrné složky a normalizován na rozsah od -1 do 1. Následně jsou vypočítány příznaky – Hjorthovy deskriptory (aktivita, mobilita a komplexnost) a vzorková entropie. Pro klasifikaci byla použita metoda podpůrných vektorů (SVM – support vector machine).

Trénování a testování bylo provedeno na 65 záznamech EKG od 10 osob. Metoda byla testována dvakrát, poprvé byly jako příznaky použity jen Hjorthovy deskriptory a Gaussovská SVM s přesností identifikace 93,8 %, podruhé byla použita vzorková entropie a Gaussovská SVM s přesností identifikace 86,2 %.

### **3.6 Metoda pro verifikaci pomocí rozhodovací neuronové sítě**

Tsu-Wang Shen a kolektiv ve své práci [17] uvedli několik metod pro verifikaci osob pomocí jednosvodového EKG. Využívají rozhodovací neuronovou síť (DBNN – decision-based neural network) a srovnávání vzorků. Při použití DBNN a srovnávání vzorků zvláště, dosáhla metoda přesnosti až 95 %, při kombinaci obou metod dokonce 100 % přesnosti. Testování probíhalo na skupině 20 osob, pro každou osobu bylo analyzováno 20 srdečních cyklů. [17]

### **3.7 Metoda pro verifikaci porovnáním QRS komplexů**

V roce 2007 byla představena metoda [18], která využívá 234 třísvodových 10 s dlouhých záznamů od 74 osob se vzorkovací frekvencí 500 Hz, elektrody jsou umístěny na ruku a levé noze. V rámci předzpracování byla odstraněna stejnosměrná složka odečtením mediánu v okně délky 1 s, dále byl signál filtrován dolní propustí s mezní frekvencí 75 Hz. Dále byly detekovány kmity R pomocí prahování absolutní hodnoty časové derivace po filtraci dolní propustí. Metoda se dívá na signál samotný jako příznakový vektor. Vybírá vždy určitý počet vzorků kolem kmitu R a porovnává tento signál (z jednoho srdečního cyklu v záznamu) a jeho první a druhou derivaci s ostatními vzorky a určuje vzdálenost mezi jednotlivými záznamy. Pro porovnání s ostatními záznamy je vybrán ten srdeční cyklus, jehož vzdálenost (rozdílnost k ostatním cyklům daného záznamu) je minimální. Signály nejsou nijak normalizovány, předpokládá se totiž, že komplex QRS se nemění ani při proměnné tepové frekvenci osoby. [18]

Trénování a testování proběhlo na 128 záznamech (2 záznamy od každé osoby). Výsledky při optimálním nastavení prahu byly FRR=3 %, FAR=2,5 %. [18]

### **3.8 Metoda využívající autokorelaci a diskrétní kosinovou transformaci**

V roce 2006 vytvořil Konstantinos N. Plataniotis a kolektiv metodu [19], která nevyužívá rozměření signálu. Nejprve je signál předzpracován pásmovou propustí s mezními

frekvencemi 0,5 a 40 Hz. Následně je ze signálu vybráno okno náhodné délky a v náhodné pozici v záznamu, přičemž okno je vždy delší než přibližná délka srdečního cyklu, takže je běžně v okně více srdečních cyklů, které ale nemusí být celé. Na základě experimentálních výsledků bylo zjištěno, že délka okna 10 s je pro tuto metodu ideální. Není potřeba přesné detekce bodů v signálu nebo překrývání jednotlivých cyklů, což znamená nízkou výpočetní náročnost a vysokou robustnost metody. [19]

Na signál ve vybraném okně je aplikována normalizovaná autokorelace. Do výsledku autokorelace se projevují hlavně vlna P, komplex QRS a vlna T. Autokorelace provádí automatickou akumulaci příznaků podobnosti přes několik cyklů signálu, nezávislou na časovém posuvu, a proto je očekáváno, že bude lépe reprezentovat jedinečné charakteristiky EKG. Následně je na signál vzniklý autokorelací aplikována diskrétní kosinová transformace (DCT – discrete cosine transform), přičemž mnohé koeficienty DCT jsou blízké nule, tedy nejsou použity, je vybráno jen několik desítek koeficientů. Tyto jsou použity jako příznakový vektor pro identifikaci osoby. Nejlepších výsledků je dosaženo tehdy, když je jako poslední koeficient příznakového vektoru vybrán první z koeficientů, který má nižší hodnotu než 0,2 % hodnoty nejvyššího koeficientu. Jako vzdálenostní metrika mezi příznakovými vektory je použita normalizovaná Euklidovská vzdálenost nebo normalizovaná Gaussovská log podobnost. [19]

Metoda byla testována na záznamech od 14 osob, jeden záznam od každé osoby byl použit pro uložení vzorového příznakového vektoru, druhý byl použit pro testování, tedy porovnání se vzorovými příznakovými vektory. Výsledné hodnoty testování byly FRR=0,02 %, FAR=1,94 %. [19]

### **3.9 Metoda využívající diskrétní vlnkovou transformaci**

V roce 2008 představili Chuang-Chien Chiu a kolektiv metodu [20] pro identifikaci osob pomocí diskrétní vlnkové transformace signálu EKG. Pro testování metody bylo použito 45 záznamů EKG (svod II) od 45 osob, záznamy délky 2 minuty byly rozděleny, první minuta byla použita pro trénování, druhá pro testování metody. [20]

Signál je vždy nejprve předzpracován horní propustí s mezní frekvencí 0,5 Hz a dolní propustí s mezní frekvencí 45 Hz. Následně je detekován komplex QRS a podle pozice komplexu QRS je signál rozdělen na jednotlivé srdeční cykly, vždy 43 vzorků před kmitem R a 84 vzorků za kmitem R (při vzorkovací frekvenci 250 Hz). Každý cyklus má tedy 128 vzorků. Takto se za sebe zařadí 4 srdeční cykly a tím vznikne umělý signál. Tento umělý signál je následně transformován vlnkovou transformací stupně 9 s použitím Haarových vlnek. Výsledné vlnkové koeficienty se následně zařadí za sebe a vznikne příznakový vektor. Příznakový vektor vzniklý ze záznamu EKG dané osoby slouží jako vzor pro identifikaci. Při identifikačním procesu je vždy vypočtena euklidovská vzdálenost mezi vzorovými vektory všech osob v databázi a příznakovým vektorem vstupního signálu. Vstupní signál je pak přiřazen k té osobě, jejíž vzor má minimální euklidovskou vzdálenost k příznakovému vektoru vstupního signálu. [20]

Přesnost identifikace 45 osob byla 95,7 %. Pro získání FAR a FRR bylo do databáze přidáno 12 záznamů od dalších osob, které ale nepatří mezi ostatních 45 osob. FAR byla 12,5 %, FRR 5,1 %. [20]



## 4. VLASTNÍ METODA PRO VERIFIKACI OSOB POMOCÍ ZÁZNAMŮ EKG

Většina biometrických systémů, včetně systému navrženého v této práci, sestává z několika částí. První částí je akvizice dat. V této práci se pracuje jednak s daty z veřejně dostupné online databáze a jednak s vlastními záznamy naměřenými pomocí chytrých hodinek, více jsou použita data popsána v kapitole 4.1. Druhou částí je extrakce příznaků, tedy nějakých měřitelných parametrů biometrických dat, které by měly být pro jednotlivé osoby charakteristické a podle kterých pak může dojít k verifikaci nebo identifikaci. Extrakce příznaků je popsána v kapitole 4.2. Třetí částí je samotný verifikační proces, kdy se na základě extrahovaných příznaků rozhoduje, zda se jedná o danou osobu nebo ne. Tato část je popsána v kapitole 4.3.

### 4.1 Data použitá pro trénování a testování metody

Při vývoji metody a pro trénování a testování klasifikátoru provádějícího verifikaci byly použity dvě databáze záznamů EKG. Jedna veřejně dostupná databáze a jedna vlastní databáze vytvořená v rámci této práce. Obě jsou popsány v následujících podkapitolách.

#### 4.1.1 Databáze záznamů z PhysioNetu

Jedna z použitých databází je online veřejně dostupná databáze s názvem ECG-ID Database [21]. Tato databáze obsahuje 310 záznamů EKG od 90 osob, přičemž každé osobě přísluší 2 až 20 záznamů. Jedná se o záznamy délky 20 s, odpovídají EKG svodu I. Vzorkovací frekvence je 500 Hz, kvantování je dvanáctibitové v rozsahu  $\pm 10$  mV. Záznamy byly pořízeny od dobrovolníků (44 mužů a 46 žen) ve věku 13 – 75 let. Každý záznam obsahuje anotace pozic kmitu R a vrcholu vlny T v deseti srdečních cyklech. Databáze obsahuje každý záznam ve dvou verzích – původní naměřený záznam a filtrovaný záznam s odstraněným nízkofrekvenčním a vysokofrekvenčním rušením. [21]

#### 4.1.2 Databáze vlastních záznamů

V rámci této práce byla vytvořena vlastní databáze záznamů EKG obsahující 285 záznamů od 18 osob (9 mužů a 9 žen), dobrovolníků. Záznamy mají délku 30 s, vzorkovací frekvenci 512,25 Hz. Záznamy byly pořízeny pomocí Apple Watch Series 4, které umožňují měření záznamů EKG a jejich export. Hodinky obsahují dvě elektrody, jedna z nich je umístěna na spodní straně hodinek a je v kontaktu s rukou, na které jsou hodinky nasazené. Druhá elektroda je umístěna na tlačítku na boční straně hodinek. Pro měření záznamu je nutné mít hodinky nasazené na jedné ruce a prst (libovolný) druhé ruky přiložit na druhou elektrodu a nehybně jej držet po celou dobu měření (30 s).

Při měření je nutné být v klidu, ruce mít položené na stole nebo v klíně a pokud možno se nehýbat, hlavně je nutné držet nehybně prst, který je položen na elektrodě. Jakýkoli pohyb prstu přiloženého na elektrodě v době měření znamená kolísání izolinie. Další pohyb rukou by zaváděl do záznamu svalové rušení.

Pro každý naměřený záznam EKG byly zaznamenány rovněž informace o měřeném osobě, konkrétně pohlaví, jestli se jedná o kuřáka, věk, hmotnost, jestli má srdeční

diagnózu, na které ruce měla hodinky nasazený, zda v poslední hodině jedla, chodila, šla po schodech, použila výtah, prováděla kancelářskou práci, zda pila v posledních dvou hodinách nápoj obsahující kofein nebo energetický nápoj a v jaké pozici osoby byl záznam měřen (sed, stoj).

Od většiny osob bylo získáno 5 záznamů EKG, od všech osob minimálně 5 záznamů. Od dvou osob bylo získáno 100 záznamů. Tyto dvě osoby mohly být následně testovány při verifikaci jako oprávněná osoba (vlastník hodinek).

Databáze naměřená v rámci této práce obsahuje záznamy pouze od 18 osob z důvodu probíhající epidemie onemocnění COVID-19, kvůli které je omezený kontakt osob, takže nebylo možné databázi bezpečně rozšiřovat dalším měřením.

Databáze záznamů naměřených v rámci této práce byla pro účely testování metody rozšířena o 579 záznamů od 82 osob, které byly naměřeny stejným způsobem zařízením stejného typu a se zaznamenáním stejných informací o měřených osobách v rámci jiné práce. Vznikla tak rozšířená databáze 864 záznamů od 100 osob.

## 4.2 Extrakce příznaků

Extrakce příznaků znamená výpočet určitých parametrů signálu a jejich uložení do příznakového vektoru, který bude následně vstupovat do klasifikátoru. Z výše popsaných metod byla čerpána inspirace pro extrakci příznaků.


### 4.2.1 Předzpracování signálu

Před samotnou extrakcí příznaků je nutné signál předzpracovat, odstranit z něho neužitečné složky neboli rušení, tedy ty složky signálu, které nejsou způsobeny elektrickou aktivitou srdce, ale nějakými okolními vlivy (pohybem, špatným kontaktem elektrody, síťovým rušením atd.). Většina výše popsaných metod využívala pro předzpracování jednoduchou filtraci pásmovou propustí pro odstranění nízkofrekvenčního a vysokofrekvenčního rušení. Při práci s databází záznamů z PhysioNetu byly využity již filtrované záznamy, takže pásmová filtrace nebyla potřebná. Při práci s vlastní databází měřenou pomocí Apple Watch by filtrace mohla být potřebná, ale filtrace odstraňovala i užitečné informace pro identifikaci, výsledky s filtrací byly horší než výsledky bez filtrace.

V této práci je pro předzpracování navíc využit adaptivní Wienerův filtr, který představil Lukáš Smítal a kolektiv [22]. Tento adaptivní filtr redukuje širokopásmové svalové rušení v signálu EKG pomocí vlnkové Wienerovy filtrace. Tento filtr využívá dyadické stacionární vlnkové transformace. Filtr adaptivně upravuje své parametry v závislosti na úrovni šumu v signálu. [22]

### 4.2.2 Rozměření signálu EKG

Pro získání intervalových, amplitudových a úhlových příznaků je nutné provést rozměření signálu neboli detekci význačných bodů v signálu a jejich označení. Pro rozměření je využita metoda, kterou v roce 2010 představil Martin Vitek a kolektiv [23]. Tato metoda je založená na spojitě vlnkové transformaci. Algoritmus detekuje pět hlavních význačných bodů – začátek komplexu QRS, konec komplexu QRS, začátek vlny P, konec vlny P a konec vlny T. Také detekuje vrcholy vln P a T a kmit R. [23] Ukázka rozměření provedená na jednom ze záznamů v databázi z PhysioNetu je na obr. 4.1.



Obrázek 4.1 Ukázka rozměření signálu EKG pomocí metody [23]

### 4.2.3 Intervalové příznaky

V první skupině příznaků, které jsou ze signálu extrahovány, jsou časové intervaly mezi jednotlivými body v signálu. Mezi osmi body v každém srdečním cyklu by mohlo vzniknout 28 intervalů. Podle výše popsaných metod, především podle metody [2], však bylo jako příznaky vybráno pouze 15 intervalů. Následně byla provedena analýza podobnosti jednotlivých příznaků a dva z příznaků byly ještě vyřazeny, protože vykazovaly přílišnou podobnost s jinými intervaly. Tím nám vzniklo 13 intervalových příznaků. Jedná se konkrétně o tyto intervaly: QR, RS, RT, PR,  $P_{\text{offsetR}}$ , délka vlny P, PQ,  $P_{\text{onsetQ}}$ ,  $P_{\text{offsetQ}}$ ,  $QT_{\text{offset}}$ ,  $ST_{\text{offset}}$ , ST, PT. Onset znamená začátek dané vlny, offset značí konec dané vlny. Použitá metoda pro rozměření signálu nedetekuje přímo pozice kmitů Q a S, ale začátek a konec komplexu QRS. Pro zjednodušení značení jsou však tyto detekované body považovány za kmitu Q a S. Intervalový příznak ST neodpovídá konvenčně používanému termínu ST úsek. ST úsek je čas od kmitu S po začátek vlny T. Intervalový příznak ST je čas od konce komplexu QRS po vrchol vlny T. Intervalový příznak,  $ST_{\text{offset}}$  je čas od konce komplexu QRS po konec vlny T. Grafické znázornění těchto použitých intervalových příznaků je na obrázku 4.2.

Příznaky, které souvisejí s vlnou P nebo T, konkrétně se jedná o intervaly RT, PR,  $P_{\text{offsetR}}$ , délka vlny P, PQ,  $P_{\text{onsetQ}}$ ,  $P_{\text{offsetQ}}$ ,  $QT_{\text{offset}}$ ,  $ST_{\text{offset}}$ , ST, PT, jsou normalizovány tím, že jejich hodnota je podělena délkou cyklu, tedy intervalem  $P_{\text{onsetT}}$ . Tato normalizace si klade za cíl omezit vliv změny tepové frekvence na hodnotu příznaků. Tepová frekvence je ovlivněna různými faktory, fyzickým i psychickým stavem osoby, aktivitou, kterou osoba dělala v době před měřením záznamu, tím, co dělá v průběhu měření nebo tím, co ho čeká poté. Tepová frekvence ovlivňuje také některé intervaly v EKG, stejně jako délku cyklu v EKG. Normalizací podle délky intervalu by se tyto změny měly alespoň částečně vykompenzovat.

Všechny tyto intervalové, stejně jako amplitudové a úhlové příznaky jsou metodou počítány pro každý srdeční cyklus zvlášť. Záznamy, se kterými metoda pracuje, mají délku 20 s nebo 30 s. Každý záznam tedy obsahuje více než přibližně 15 srdečních cyklů. Neúplné srdeční cykly na začátku a konci záznamu jsou z analýzy vyloučeny. Pokud

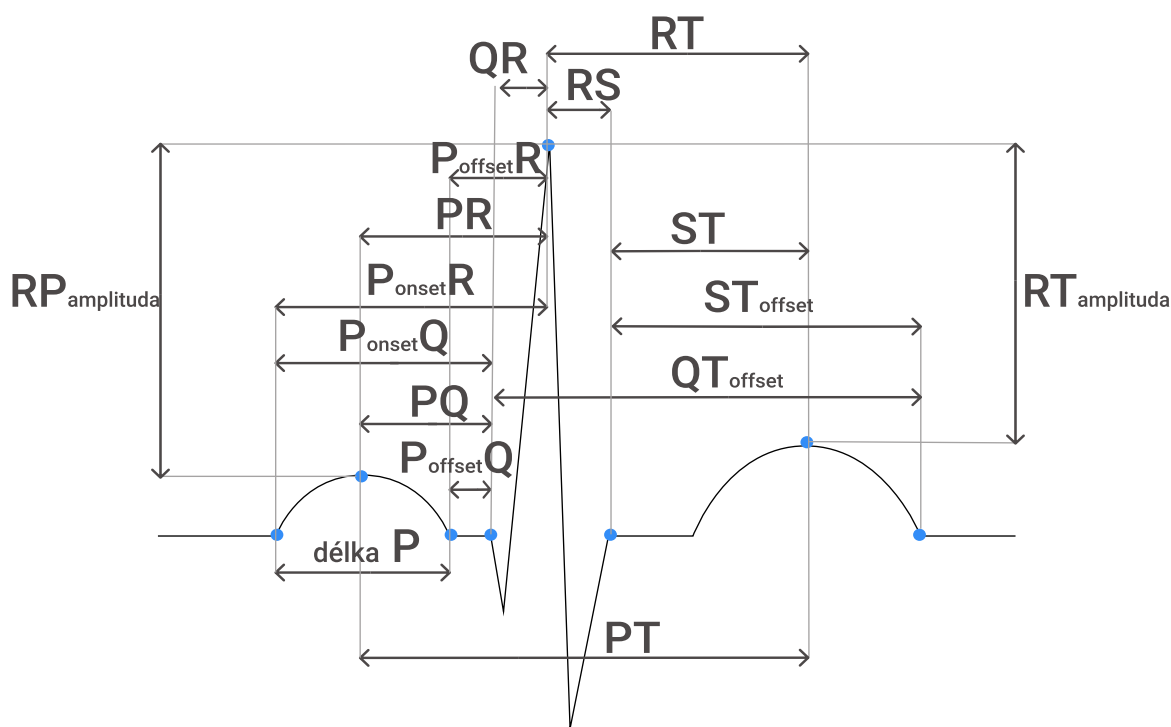
v některém srdečním cyklu selže detekce některého význačného bodu, je tento bod přibližně určen na základě korespondujících detekovaných bodů sousedních srdečních cyklů a průměrné hodnoty.

Každý z intervalů (amplitud, úhlů) je tedy pro jednotlivý záznam obsažen několikrát. Z tohoto vektoru hodnot jsou odstraněny dvě nejvyšší a dvě nejnižší hodnoty. Tento krok má za cíl odstranit extrémní hodnoty, které se v záznamu mohou náhodně vyskytnout na základě různých vlivů. Ze zbylých hodnot daného intervalu je vypočítán aritmetický průměr, zůstane tedy jedna výsledná hodnota každého příznaku pro daný záznam EKG. Takto získáme od každého ze 13 intervalů v daném záznamu jednu hodnotu. Tyto hodnoty jsou brány jako finální příznaky.

#### 4.2.4 Amplitudové příznaky

Druhou skupinou příznaků jsou potenciálové rozdíly mezi vrcholem R a jiným význačným bodem. Na základě inspirace metodou [2] se jedná o tyto čtyři amplitudové hodnoty: RP, RQ, RS a RT. Opět jsou počítány hodnoty pouze celých srdečních cyklů v záznamu, jsou odstraněny extrémní hodnoty (dvě nejvyšší a dvě nejnižší) a ze zbylých hodnot je vypočten aritmetický průměr.

Po analýze podobnosti příznaků a jejich přínosu pro verifikaci byly z metody vyloučeny amplitudy RQ a RS. Zůstaly tedy dva amplitudové příznaky, konkrétně  $RP_{\text{amplituda}}$  a  $RT_{\text{amplituda}}$ . Všechny použité intervalové a amplitudové příznaky jsou znázorněny na obrázku 4.2.




Obrázek 4.2 Intervalové a amplitudové příznaky

#### 4.2.5 Úhlové příznaky

Třetí skupinou příznaků jsou úhlové příznaky vytvořené podle metody [2]. Jedná se o tři úhly. Úhel mezi vrcholem vlny P, vrcholem Q a vrcholem R, druhý úhel mezi vrcholem Q,

R a S, a třetí úhel mezi vrcholy R, Q a vrcholem vlny T. Příznaky by měly částečně souviset se strmostí komplexu QRS a s velikostí vln P a T. Všechny úhly jsou vyznačeny v obrázku 4.3. Opět platí, že jsou úhly počítány jen pro celé cykly, dvě nejmenší a dvě největší hodnoty daného úhlu v záznamu jsou odstraněny a ze zbytku je vypočten aritmetický průměr, který je finálním příznakem.

Na základě analýzy podobnosti příznaků byly nejprve vyřazeny dva z úhlových příznaků, protože všechny úhly v daném záznamu byly velice podobné. Následně byl z dalšího využití odstraněn i třetí úhlový příznak pomocí zpětné selekce příznaků.



Obrázek 4.3 Úhlové příznaky, převzato z [2]

#### 4.2.6 Příznaky variability intervalů

Dalším z příznaků je rozptyl RR intervalu, opět inspirován metodou [2]. Myšlenka je taková, že různé osoby by měly mít různou variabilitu srdečního rytmu. Měřtkem variability je rozptyl. Z polohy kmitu R ve všech úplných cyklech záznamu jsou vypočteny RR intervaly, tedy časové intervaly mezi cykly. Z těchto je vypočten rozptyl, který je využit jako příznak. Rozptyl RR intervalu byl rovněž analyzován z hlediska interpersonální variability. Ta však nebyla velká, příznak se mnohdy lišil více mezi záznamy jedné osoby než mezi osobami. Proto není příznak v metodě využit.

Poslední skupina příznaků je odvozena z intervalů a amplitud v rámci jednotlivých cyklů, jak jsou popsány v kapitole 4.2.3 a 4.2.4. Z vektoru hodnot daného intervalu je vypočtena směrodatná odchylka, která je podělena aritmetickým průměrem hodnot. Konkrétně bylo počítáno 7 těchto příznaků odvozených od intervalů QR, RS, RT,  $RT_{offset}$ , PR,  $P_{onset}R$  a  $P_{offset}R$ . Následně byl analyzován přínos těchto příznaků pro zlepšení výsledků verifikace. Z této analýzy byl vyvozen závěr, že tyto příznaky příliš (nebo vůbec) nepřispívají ke zlepšení přesnosti verifikace. Byl zachován pouze jeden z těchto příznaků, konkrétně variabilita intervalu PR, tedy směrodatná odchylka intervalů PR v záznamu dělená aritmetickým průměrem těchto intervalů. Podobně byly extrahovány i příznaky variability amplitudových rozdílů (4 příznaky – variabilita amplitud mezi PR, QR, RS a RT), které ale byly na základě zpětné selekce také vyřazeny z této metody.

## 4.3 Verifikační a identifikační proces

Cílem verifikačního procesu je na základě extrahovaných příznaků rozhodnout, zda se jedná o jednu konkrétní osobu nebo nejedná. Tento problém tedy můžeme definovat jako binární klasifikační úlohu, kdy na základě vstupních příznaků určíme, zda systému předkládané příznaky patří do první kategorie (jedná se o danou konkrétní osobu) nebo do druhé kategorie (jedná se o jinou než danou konkrétní osobu). Identifikace je rovněž klasifikační úlohou, ale s více třídami. V této práci je pro klasifikaci využit náhodný les.

### 4.3.1 Klasifikační strom

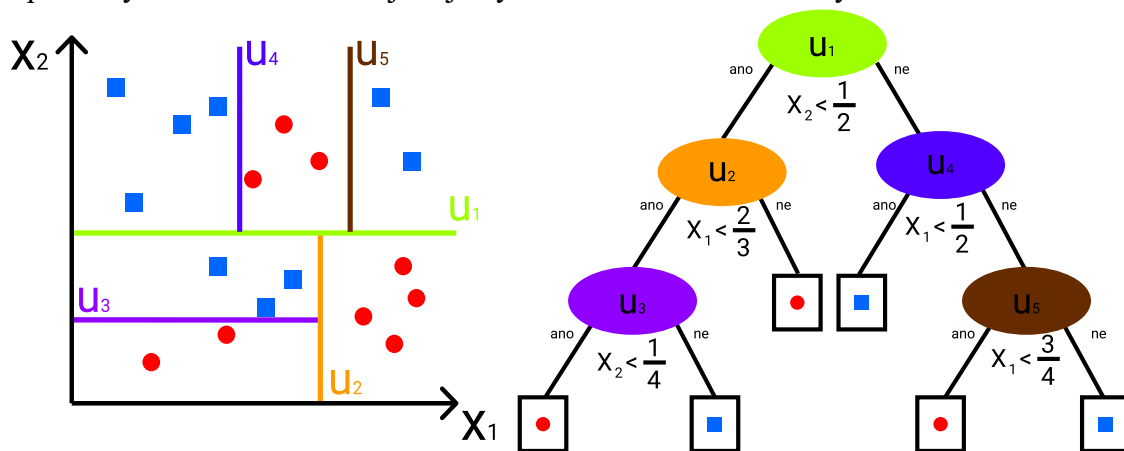
Klasifikační strom je jednoduchý algoritmus strojového učení. Strom se skládá z uzlů a větví, uzly mohou být počáteční, průběžné a koncové. Cílem klasifikačního stromu je rozdělit příznakový prostor na oblasti, které přísluší vždy jen jedné třídě. Tříd může být obecně mnoho (v identifikačních modelech), ale v modelovém stromě na obr. 4.4 a ve verifikačních modelech jsou třídy dvě. Rozdělení prostoru na oblasti příslušící jednotlivým třídám se provádí na základě trénovacích dat. V každém uzlu dochází k rozdělení vstupního příznakového prostoru na dvě části, na začátku je jen jedna nerozdělená oblast. Rozdělení je provedeno tak, aby se minimalizovala klasifikační chyba (např. počet špatně zařazených vzorků).

Jako klasifikační chybová funkce neboli měřítko nečistoty klasifikace v dané oblasti se využívá jedna ze tří funkcí. První možností je absolutní počet nesprávně zařazených vzorků, tedy počet vzorků v dané oblasti, které nespádají do třídy, která je dané oblasti přiřazena (která obsahuje v dané oblasti nejvíce vzorků). Druhým chybovým kritériem je Gini index, který je popsán v rovnici 4.1, kde  $K$  je počet tříd, jednotlivé třídy se indexují pomocí  $k$ ,  $\hat{p}_{mk}$  je poměr vzorků třídy  $k$  v uzlu  $m$ . Gini index se v praxi využívá více a je citlivější na změny pravděpodobnosti v uzlech než počet nesprávně zařazených vzorků. Třetím chybovým kritériem je křížová entropie, je popsána rovnicí 4.2, přičemž značení je stejné jako v případě Gini indexu. [24]

$$\sum_{k=1}^K \hat{p}_{mk}(1 - \hat{p}_{mk}) \quad (4.1)$$

$$\sum_{k=1}^K \hat{p}_{mk} \log \hat{p}_{mk} \quad (4.2)$$

Příklad klasifikačního stromu vidíme na obr. 4.4. Ve 2D příznakovém prostoru s příznaky  $X_1$  a  $X_2$  se nacházejí objekty dvou tříd – červené kruhy a modré čtverce.



Obrázek 4.4 Příklad klasifikačního stromu

Algoritmus má dvě fáze. V první fázi probíhá trénování neboli učení na základě trénovacích dat, ve druhé fázi pak probíhá samotná klasifikace vzorků neznámé třídy, tedy rozhodování o jejich zařazení do tříd.

Ve fázi trénování probíhají v každém uzlu postupně následující kroky: pokud není strom příliš velký (není překročen maximální počet uzlů v celém stromě nebo maximální „vzdálenost“ od kořene k současnemu uzlu – tzv. hloubka stromu) nebo dokud není dosaženo maximální čistoty v daném uzlu (v dané oblasti se nacházejí vzorky jen jedné třídy), nebo dokud není celková chyba stromu dostatečně nízká, dochází k rozdělení příznakového prostoru. K rozdělení dochází podle jedné proměnné, přičemž není předem dané podle které. Pomocí úplného prohledávání je zjištěno, pro které rozdělení (podle které proměnné a s jakým prahem je prostor rozdělen) se nejvíce sníží chybová funkce. Následně dojde k rozdělení prostoru, vznikají nové dvě podoblasti – dva nové uzly.

Ve stromu na obrázku 4.4 došlo v počátečním uzlu  $u_1$  k rozdělení příznakového prostoru podle proměnné  $x_2$  s prahem 0,5, tím došlo ke zmenšení chybové funkce (počtu špatně klasifikovaných vzorků) z 9 na 6. Vzniklé prostory se následně dělí nezávisle na sobě pomocí dalších uzlů, dokud nejsou v každém koncovém uzlu (ve výsledných oblastech) přítomny trénovací vzorky pouze jedné třídy. Uzel  $u_2$  dělí prostor pod úsečkou  $u_1$  podle příznaku  $x_1$  s prahem  $2/3$ , snižuje chybu z 6 na 5, jedna ze vzniklých oblastí pak obsahuje pouze červené kruhy, takže vzniká koncový uzel a daná oblast se dále nedělí. Uzel  $u_3$  dělí druhou vzniklou oblast podle proměnné  $x_2$  s prahem  $1/4$  na dvě koncové oblasti a snižuje chybu z 5 na 3. Dále uzel  $u_4$  dělí oblast nad úsečkou  $u_1$  podle proměnné  $x_1$  s prahem  $1/2$ , snižuje chybu ze 3 na 2 a vzniká jeden koncový uzel. A konečně uzel  $u_5$  dělí poslední nejednotnou oblast podle proměnné  $x_1$  a prahu  $3/4$  na dvě koncové oblasti a snižuje tak chybu ze 2 na 0 špatně zařazených trénovacích vzorků.

Příznakový prostor je tedy rozdělen ve stromě na obr. 4.4 na šest oblastí, obecně může být jakýkoli počet oblastí, výsledný počet oblastí závisí na vstupních datech a podmínkách ukončení učení, tedy omezení velikosti stromu, hloubky stromu nebo splnění dostatečné čistoty koncových oblastí. Obecně nemusí být chyba natrénovaného stromu nulová, tedy nemusí být úplná čistota koncových uzlů, ale pro ukončení učení stačí, když chyba klesne pod nastavený práh. Pokud koncová oblast obsahuje trénovací vzorky více tříd, pak se výsledná třída dané oblasti určí podle toho, která třída má v dané oblasti nejvíce vzorků.

Když je klasifikační strom natrénovaný, může se použít pro klasifikaci neznámých vzorků. Na základě hodnot příznaků neznámého vzorku se každý testovací vzorek nachází některé oblasti. Vzorek je pak označen tou třídou, která je dané oblasti přiřazena.

Klasifikační strom je jednoduchý a intuitivní algoritmus, který nevyžaduje normalizaci dat. Jeho nevýhodou je nestabilita, to znamená že rozdělení příznakového prostoru je silně závislé na vstupních datech. Další nevýhodou je sklon k přeučení – prostor je pomocí složitého stromu rozdělen přesně podle vstupních dat, takže trénovací kritérium je minimální. Když pak ale strom klasifikuje nová data, dochází k nesprávnému zařazování – algoritmus má špatnou generalizační schopnost. Tyto problémy mohou být vyřešeny použitím náhodného lesa.

### 4.3.2 Náhodný les

Náhodný les (random forest) neboli les náhodných stromů je algoritmus strojového učení, který kombinuje určitý počet náhodných stromů. Každý ze stromů rozhoduje nezávisle na ostatních, rozhodnutí celého náhodného lesa se pro klasifikaci určuje většinovou

volbou. Jedná se o algoritmus strojového učení, takže proto, aby klasifikátor fungoval (aby uměl na základě vstupních příznaků rozhodnout, do které třídy vstupní vzorek patří), se musí naučit na trénovacích datech. [25]

Myšlenka náhodného lesa spočívá v kombinaci více jednoduchých klasifikátorů v jeden silný klasifikátor. Do jednotlivých stromů nevstupují všechna trénovací data, ale pouze náhodně vybraný vzorek dat, takže každý strom je trénován na jiných datech. Strom také nevyužívá všech vybraných dat pro učení, ale vybraný vzorek dat ještě rozdělí na tzv. In-bag data a Out-of-bag data, přičemž In-bag data tvoří přibližně dvě třetiny dat a jsou použita pro trénování stromu. Out-of-bag data obsahují přibližně jednu třetinu dat a jsou použita pro odhad chyby stromu – validaci. Navíc v každém uzlu každého stromu se náhodně vybírá jen určitý počet proměnných (příznaků), na základě kterých může dojít k rozdělení prostoru. Nemusí tedy jít vždy o to nejlepší možné rozdělení ze všech proměnných, ale pouze nejlepší rozdělení na základě vybraných proměnných. Při samotné klasifikaci rozhodne o zařazení do některé třídy každý strom zvlášť, rozhodnutí celého náhodného lesa se pak určí jako většinová volba, tedy výsledná třída je ta, do které daný vzorek zařadilo nejvíce stromů. [25]

Skutečnost, že náhodný les provádí validaci jednotlivých stromů, umožňuje použít více z dostupných dat pouze pro trénování, případně se pro testování spolehlivosti může použít pouze validace pomocí Out-of-bag dat. Toto testování je důvěryhodnější než běžně používaná křížová validace. Ovšem testování na nezávislých datech je v každém případě lepší variantou, ale je pro to potřeba mít vyhrazena pouze testovací data. Velkou výhodou náhodného lesa je také možnost snadno určit, které příznaky jsou pro rozhodování nejčastěji využívány, tedy důležitost příznaků. Použití více nezávislých stromů také zabraňuje přeučení klasifikátoru, takže je lepší generalizace. [25]



## 5. TESTOVÁNÍ A SELEKCE PŘÍZNAKŮ

V této kapitole je shrnuto, jakým způsobem byly příznaky analyzovány podle toho, jak jsou unikátní pro člověka, tedy z hlediska interpersonální variability, a také zda není příznak redundantní neboli zda není více příznaků, které jsou si velice podobné nebo jsou korelované.


### 5.1 Grafické hodnocení příznaků

První metoda hodnocení příznaků je grafické hodnocení příznaků. Hodnocení probíhalo na databázi z PhysioNetu, konkrétně na záznamech 13 osob. Pro každý z hodnocených příznaků byla vykreslena řada grafů typu box and whiskers.

Box and whiskers grafy znázorňují variabilitu dat a také rozložení hodnot. Každý graf sestává z obdélníku (box), jehož horní a spodní strana leží na hodnotě kvartilů. Uvnitř obdélníku je červenou čarou zvýrazněna hodnota mediánu. Pokud jsou data málo variabilní, je obdélník krátký, pokud je variabilita velká, je obdélník dlouhý. Z obdélníku vycházejí nahoře a dole čárkované čáry (whiskers), které vyjadřují variabilitu dat mimo kvartily, čáry končí na maximální (horní čára) a minimální hodnotě dat (spodní čára). Pokud se v datech vyskytují nějaké odlehlé hodnoty, jsou vyznačeny zvlášť pomocí červeného znaku +.


Pro každý hodnocený příznak je vykresleno 13 box and whiskers grafů v jednom obrázku, každý pro jednu osobu. Pro jednotlivé osoby jsou grafy vytvářeny z tolika hodnot, kolik má daná osoba v databázi záznamů. Můžeme tak u každého příznaku vidět, v jakém rozmezí leží hodnoty každé osoby, jak jsou hodnoty u každé osoby variabilní a jak se liší od ostatních osob. Ideální příznak by obsahoval hodnoty, které by se u jednotlivých osob vzájemně nepřekrývaly a u každé osoby měly nízkou variabilitu.

#### 5.1.1 Intervalové příznaky




Obrázek 5.1 Znázornění variability intervalů QR (vlevo) a RS (vpravo)

Intervaly QR vykazují značnou interpersonální variabilitu, většina osob má rovněž nízkou variabilitu těchto intervalů mezi záznamy. Osoba 4 má vyšší variabilitu tohoto příznaku mezi záznamy (viz obr.5.1 vlevo). U intervalů RS opět pozorujeme jistou interpersonální variabilitu, u všech osob kromě osoby 4 rovněž poměrně nízkou variabilitu mezi záznamy (viz obr.5.1 vpravo). Hodnota příznaků je v sekundách.




**Obrázek 5.2 Znáznornění variability intervalů RT (vlevo) a RT<sub>offset</sub> (vpravo)**

Příznaky RT a RT<sub>offset</sub> mají téměř totožné rozložení hodnot příznaků, které jsou jen posunuty (viz obr. 5.2). Příznaky jsou tedy korelované a není potřeba je do klasifikátoru posílat oba, jeden z nich by byl redundantní. Pokud bychom využili oba příznaky, mohlo by to negativně ovlivnit přesnost klasifikace, tento příznak by měl oproti ostatním relativně vyšší váhu. Hodnoty obou příznaků jsou bezrozměrné. Samotné intervaly mají jednotku sekundy, ale jsou děleny jiným intervalem, takže výsledek je bezrozměrný.




**Obrázek 5.3 Znáznornění variability intervalů PR (vlevo) a P<sub>onsetR</sub> (vpravo)**


Příznaky PR a P<sub>onsetR</sub> jsou si rovněž velmi podobné svým rozložením hodnot (viz obr. 5.3), proto z nich byl využit pouze jeden, konkrétně interval PR. Příznaky jsou bezrozměrné.




**Obrázek 5.4** Znáznornění variability intervalů  $P_{\text{offset}R}$  (vlevo) a délek vlny P (vpravo)




**Obrázek 5.5** Znáznornění variability intervalů PQ (vlevo) a  $P_{\text{onset}Q}$  (vpravo)



**Obrázek 5.6** Znáznornění variability intervalů  $P_{\text{offset}Q}$  (vlevo) a  $QT_{\text{offset}}$  (vpravo)



**Obrázek 5.7** Znáznornění variability intervalů  $ST_{offset}$  (vlevo) a ST (vpravo)




**Obrázek 5.8** Znáznornění variability intervalů PT


Příznaky znázorněné na obrázcích 5.4-5.8 mají všechny určitou interpersonální variabilitu a nevykazují podobnost s jinými příznaky, a proto byly zachovány pro použití při identifikaci. Všechny tyto příznaky jsou bezrozměrné.

### 5.1.2 Amplitudové příznaky

V této kapitole je zobrazena variabilita amplitudových příznaků, hodnota příznaku je v milivoltech. Příznaky amplitudy RP, RQ a RS mají téměř totožné rozložení hodnot (viz obr. 5.9 a 5.10), proto z nich byl použit pouze jeden, a to amplituda RP. Amplituda RT je ostatním amplitudám také částečně podobná svým rozložením hodnot, ale není totožná, takže byl tento příznak ponechán.




**Obrázek 5.9** Znázornění variability amplitud RP (vlevo) a RQ (vpravo)




**Obrázek 5.10** Znázornění variability amplitud RS (vlevo) a RT (vpravo)

### 5.1.3 Úhlové příznaky




**Obrázek 5.11** Znázornění variability úhlů PQR



**Obrázek 5.12** Znázornění variability úhlů QRS (vlevo) a RST (vpravo)


Všechny tři úhlové příznaky mají vysokou podobnost. Proto byl pro další analýzu využit pouze jeden z těchto příznaků. Ten však byl vyřazen při následné analýze - zpětné selekci příznaků.

#### 5.1.4 Příznaky variability intervalů




**Obrázek 5.13** Znázornění variability rozptylu intervalů RR


Příznak rozptyl intervalů RR je na základě této analýzy podezřelý (viz obr. 5.13). Hodnoty příznaku se u osoby 4 se pohybují v jiných řádech, variabilita ostatních nelze dobře určit. Na základě další analýzy pomocí zpětné selekce byl tento příznak odstraněn.




**Obrázek 5.14** Znázornění variability příznaků variability intervalů QR (vlevo) a RS (vpravo)



**Obrázek 5.15** Znázornění variability příznaků variability intervalů RT (vlevo) a  $RT_{\text{offset}}$  (vpravo)



**Obrázek 5.16** Znázornění variability příznaků variability intervalů PR (vlevo) a  $P_{\text{onsetR}}$  (vpravo)



**Obrázek 5.17** Znáznornění variability příznaků variability intervalů  $P_{\text{offsetR}}$

Kromě variability intervalů  $RT$  a  $RT_{\text{offset}}$ , které nevykazují interpersonální variabilitu, by tyto příznaky na základě grafické analýzy mohly být alespoň částečně přínosné. Příznaky rozptylu intervalů  $PR$  a  $PR_{\text{onset}}$  jsou si velmi podobné. Na základě zpětné selekce však vyšlo najevo, že zbylé příznaky příliš nezlepšují výsledek klasifikace. Ze všech příznaků variability intervalů je pro klasifikaci využit pouze jeden příznak – variabilita intervalu  $PR$ . Pomocí zpětné selekce byly vyřazeny i příznaky variability amplitudových rozdílů, které byly rovněž extrahovány.

## 5.2 Redukce příznaků pomocí zpětné selekce

Metoda zpětné selekce spočívá v tom, že jsou pro klasifikaci nejprve využity všechny dostupné (nebo dosud nevyřazené) příznaky a testuje se přesnost klasifikace. Následně je testována přesnost klasifikace po odstranění některého příznaku. Pokud odstranění příznaku nepřinese zhoršení výsledku, je příznak odstraněn. Odstranění některých příznaků může vést dokonce ke zlepšení výsledku.

Touto metodou byly testovány téměř všechny příznaky a několik z nich bylo odstraněno, v předchozích kapitolách je již zmíněno, o které příznaky se jedná. Testování a zpětná selekce příznaků byla provedena za použití náhodného lesa se 100 stromy jako klasifikátoru. Jako testovací databáze byla použita databáze z PhysioNetu.



## **6. TRÉNOVÁNÍ MODELŮ A TESTOVÁNÍ ÚSPĚŠNOSTI VERIFIKACE A IDENTIFIKACE**

### **6.1 Trénování a testování verifikace osob na databázi z PhysioNetu**

Databáze z PhysioNetu obsahuje 310 záznamů od 90 osob. Od většiny osob jsou zde však pouze dva nebo tři záznamy. Pouze dvě osoby mají více než deset záznamů. Pro trénování a testování modelu pro verifikaci osoby je potřeba více záznamů. Proto byly na této databázi vytvořeny a testovány pouze 2 modely. První model je naučen tak, že verifikuje, zda patří vstupní záznam osobě 1 nebo nepatří, druhý model verifikuje záznamy vzhledem k osobě 2. Jako klasifikátor je v obou modelech využit náhodný les o 100 stromech.

#### **6.1.1 Model 1**

Osoba 1 má v databázi 18 záznamů, se kterými se pracuje. 13 záznamů osoby 1 a 50 záznamů ostatních osob je použito pro trénování. Zbýlých 5 záznamů osoby 1 a 114 záznamů ostatních osob je využito pro testování. Záznamy pro trénování a testování jsou vybírány náhodně.

Trénování a testování proběhlo třicetkrát. Výsledky z jednotlivých běhů byly zprůměrovány. Tento postup byl zvolen proto, aby byl potlačen vliv náhody při výběru trénovacích a testovacích záznamů.

Průměrné výsledky jsou následující: TRR=94,50 %, TAR 63,33 %. Výsledná hodnota TRR je velmi dobrá, ovšem TAR je dosti nízká. Předpokládá se, že když bude k dispozici více dat pro trénování, dosáhne metoda lepších výsledků.

#### **6.1.2 Model 2**

Osoba 2 má v databázi 14 záznamů, se kterými se pracuje. 10 záznamů osoby 2 a 50 záznamů ostatních osob je použito pro trénování. Zbýlé 4 záznamy osoby 2 a 118 záznamů ostatních osob je využito pro testování. Záznamy pro trénování a testování jsou vybírány náhodně.

Trénování a testování proběhlo stejně jako u modelu 1 třicetkrát, výsledky z jednotlivých běhů byly zprůměrovány. Průměrné výsledky jsou následující: TRR=96,38 %, TAR 34,17 %. Zde je hodnota TRR ještě lepší než u modelu 1. Naopak TAR je výrazně horší. Zde bylo ještě méně trénovacích záznamů, a i zde je předpoklad zlepšení při použití více záznamů.

## 6.2 Trénování a testování verifikace osob na rozšířené vlastní databázi záznamů

Pro testování metody byla použita rozšířená databáze vlastních záznamů, která obsahuje 864 záznamů od 100 osob. Pro každou ze 14 osob, které mají v databázi více než 10 záznamů, bylo provedeno trénování verifikačního modelu a testování jeho úspěšnosti.

Pro verifikační model každé ze 14 osob bylo ze záznamu dané osoby náhodně vylosováno 90 % záznamů (zaokrouhлено dolů) pro trénování (učení) modelu a validaci v rámci náhodného lesa. Zbylé záznamy dané osoby byly použity pro testování modelu. Z ostatních osob (z 86 osob které mají méně než 10 záznamů) byl vylosován určitý počet osob, jejichž záznamy byly použity pro trénování a validaci modelu jako „zbytek světa“, záznamy zbylých osob byly použity pro testování modelu. Počet osob „zbytku světa“ pro trénování a validaci byl určen podle počtu trénovacích záznamů od dané osoby. Pokud má osoba více než 40 záznamů, bylo pro trénování vybráno 40 osob ze „zbytku světa“. Pokud má osoba více než 24 záznamů (a méně než 40), bylo pro trénování vybráno 30 osob. Pokud má osoba méně než 24 záznamů (kromě osoby 2212), bylo pro trénování vybráno 20 osob. Pro osobu 2212, která má ze všech 14 osob nejméně záznamů (12) bylo pro trénování vybráno 12 osob ze „zbytku světa“. Tyto počty osob, jejichž záznamy byly použity pro trénování, byly určeny heuristicky. Počty trénovacích a testovacích záznamů dané osoby nebo počty osob jejichž záznamy byly použity pro trénování a testování jsou uvedeny v tabulce 6-1. Výběr záznamů/osob pro trénování a testování je prováděn vždy náhodně.

**Tabulka 6-1 Počty trénovacích a testovacích záznamů a osob pro jednotlivé verifikační modely**

ID osoby	1201	1202	1205	1206	1207	1208	1212
<b>Záznamů v databázi celkem</b>	28	21	88	21	24	19	15
<b>Záznamů pro trénování</b>	25	18	79	18	21	17	13
<b>Záznamů pro testování</b>	3	3	9	3	3	2	2
<b>Ostatních osob pro trénování</b>	30	20	40	20	20	20	20
<b>Ostatních osob pro testování</b>	56	66	46	66	66	66	66
ID osoby	1428	2200	2201	2204	2205	2212	2421
<b>Záznamů v databázi celkem</b>	97	33	28	25	14	12	98
<b>Záznamů pro trénování</b>	87	29	25	22	12	10	88
<b>Záznamů pro testování</b>	10	4	3	3	2	2	10
<b>Ostatních osob pro trénování</b>	40	30	30	20	20	12	40
<b>Ostatních osob pro testování</b>	46	56	56	66	66	74	46

Pro každou ze 14 osob je natrénováno a otestováno 300 modelů, pokaždé s jiným náhodným výběrem, jejichž výsledky se následně průměrují, aby byl co nejvíce smáznán vliv náhodně příliš dobrých nebo špatných výsledků. Tento přístup opakovaného náhodného výběru dat pro trénování a testování se nazývá „holdout“ metoda, jedná se o jeden z typů křížové validace pro hodnocení úspěšnosti klasifikátorů.

Tabulka 6-2 obsahuje výsledky testování. Pro každou osobu tabulka obsahuje průměrnou hodnotu TAR, TRR, FAR a FRR ze všech 300 realizací modelu (výsledky testování na testovacím souboru dat). Tabulka také obsahuje průměrnou hodnotu OOB

error modelu, tedy klasifikační chybu spočítanou pro každý strom v náhodném lese testováním na OOB datech pro daný strom, tedy na validačních datech, zprůměrovaná ze všech stromů v náhodném lese. Při trénování náhodného lesa je pro každý strom vybrána jen část dat, data vybraná pro daný strom jsou ještě dále rozdělena na trénovací data (in-bag data) a validační data (out-of-bag data, OOB data).

**Tabulka 6-2 Výsledky testování verifikačních modelů pro jednotlivé osoby**

ID osoby	1201	1202	1205	1206	1207	1208	1212
TAR [%]	95,11	85,78	78,04	59,33	78,00	90,50	88,50
TRR [%]	96,67	97,06	92,14	90,96	93,51	96,42	98,84
FAR [%]	3,33	2,94	7,86	9,04	6,49	3,58	1,16
FRR [%]	4,89	14,22	21,96	40,67	22,00	9,50	11,50
OOB error [%]	3,40	7,58	14,15	14,90	10,03	5,44	5,09
ID osoby	1428	2200	2201	2204	2205	2212	2421
TAR [%]	93,90	72,08	99,11	55,78	98,17	87,33	97,83
TRR [%]	98,39	97,19	98,17	97,69	98,67	92,90	98,01
FAR [%]	1,61	2,81	1,83	2,31	1,33	7,10	1,99
FRR [%]	6,10	27,92	0,89	44,22	1,83	12,67	2,17
OOB error [%]	6,82	11,03	2,71	10,97	2,69	7,42	5,41

Úspěšnost klasifikace je u některých osob velmi vysoká, nejvyšší úspěšnost verifikace vykazuje model osoby 2201, kde je TAR 99,11 % a TRR 98,18 %, také validační chyba 2,71 % je velice nízká.

Některé osoby (např. osoby 2204, 1206) mají vysokou FRR (55,78 % a 59,33 %), neboli záznamů oprávněné osoby, které byly verifikačním modelem vyhodnoceny jako záznamy jiné osoby. V praxi by to znamenalo častou nutnost opakování verifikace, než by oprávněná osoba byla připuštěna. Tyto osoby nemají příliš charakteristické rysy EKG oproti ostatním osobám a jejich verifikace je tedy obtížná. Modely jsou nastaveny tak, že pokud je vyšší nejistota o tom, zda se jedná o danou osobu, je osoba pravděpodobněji klasifikována jako „zbytek světa“. Toto nastavení je zajištěno dostatečně velkým počtem trénovacích záznamů osob jiných než dané osoby a nerovnoměrným priorem. Prior neboli apriorní znalost určuje, jaký je pravděpodobný poměr měření od dané osoby a od ostatních osob, a tedy jak často by přibližně mělo docházet k připuštění/zamítnutí měřené osoby. Tato apriorní znalost se využívá při učení modelu a při samotné verifikaci nehraje žádnou roli.

Pro zhodnocení navržené metody je možné hodnotit jednak výsledky jednotlivých modelů pro jednotlivé osoby a zhodnotit na kterých osobách metoda dosahuje vynikajících výsledků a na kterých osobách metoda selhává. Pro celkové zhodnocení by mohly být užitečné průměrné hodnoty výsledků od všech osob. Průměrná TAR je tedy 84,25 %, (průměrná FRR je 15,75 %). Tato hodnota ukazuje, že při použití této metody bude oprávněná osoba průměrně v 15,75 % případů nepřipuštěna, přičemž nepřipuštění může být více či méně časté v závislosti na tom, jak je EKG dané osoby jedinečné vůči ostatním osobám. Zlepšení těchto hodnot by vedlo k pohodlnějšímu užívání verifikačního systému ze strany oprávněné osoby a snížení četnosti nutného opakování verifikace.

Průměrná TRR je 96,19 % (průměrná FAR je 3,81 %). Tyto hodnoty ukazují, že při použití této metody pro verifikaci osob bude ve 3,81 % případů neoprávněná osoba

připuštna. Cílem verifikačního systému je zabezpečit, aby přístup získala pouze oprávněná osoba. Tato verifikační metoda tedy není dokonale bezpečná vůči neoprávněnému přístupu. Pokud by se však tato metoda, která svou podstatou zajišťuje velmi obtížnou falsifikaci, spojila s jinou metodou, která zajišťuje nižší riziko připuštění neoprávněné osoby svou jedinečností, mohl by vzniknout velice bezpečný multimodální verifikační systém.

### **6.3 Trénování a testování identifikačních modelů**

Na rozšířené vlastní databázi záznamů (846 záznamů od 100 osob) bylo provedeno trénování a testování několika modelů identifikace osob. První model obsahuje pouze 14 osob s více než 10 záznamy, model neobsahuje osoby z okolí. Druhý model obsahuje 31 osob s více než 5 záznamy a žádné ostatní osoby. Třetí model provádí identifikaci 14 osob s více než 10 záznamy ve větší populaci včetně ostatních osob, čtvrtý model identifikuje 31 osob s více než 5 záznamy v populaci s ostatními osobami.

#### **6.3.1 Model identifikace 14 osob v populaci 14 osob**

Tento model provádí identifikaci osob v populaci obsahující 14 osob s více než 10 záznamy na osobu. Pro identifikaci je využit klasifikátor typu náhodný les o 40 náhodných stromech. Pro trénování a validaci modelu je použito 10 náhodně vybraných záznamů od každé z osob. Pro testování jsou použity všechny zbývající záznamy každé z osob, tedy pro některou osobu jsou pouze 2 testovací záznamy, pro jinou osobu je 88 testovacích záznamů. Pro testování byla použita 300-násobná metoda „holdout“, tedy cyklus trénování a testování byl proveden třistakrát pokaždé s jiným náhodným výběrem trénovacích a testovacích dat, výsledky testování byly zprůměrovány.

Výsledky testování mají pro každou realizaci modelu podobu tabulky, která ukazuje, jaké ID bylo identifikátorem přiděleno záznamům od jednotlivých osob. Je to vlastně čtvercová matice, v tomto případě velikosti 14x14. Na hlavní diagonále jsou počty záznamů dané osoby, které identifikátor správně přiřadil k dané osobě. Mimo hlavní diagonálu se nacházejí nesprávně identifikované záznamy. Přesnost identifikace dá nejlépe kvantifikovat jako míra správně identifikovaných záznamů, tedy součet všech správně identifikovaných záznamů (součet prvků matice na hlavní diagonále) dělený součtem všech prvků matice. V tabulce také lze pozorovat která konkrétní osoba je identifikována špatně.

Tabulka 6-3 obsahuje výsledky jedné ze 300 realizací identifikačního modelu pro 14 osob. Prvky na hlavní diagonále jsou zvýrazněné pro lepší optickou orientaci v tabulce. Přesnost identifikace této konkrétní realizace je 83,55 %. Průměrná přesnost identifikace ze všech 300 realizací modelu je 81,46 %. Tento model nejčastěji chybí při identifikaci osoby 1205, kdy 44 záznamů přiřazuje správně této osobě, ale 12 záznamů přiřazuje osobě 1206 a 22 záznamů dalším pěti osobám. Identifikace osoby 1205 v této realizaci modelu má přesnost pouze 59,52 %. Také osoba 2204 má velmi nízkou přesnost 53,3 %. Naopak osoby 1201, 1208, 1212, 2205 a 2212 mají 100 % úspěšnost identifikace.

**Tabulka 6-3 Výsledky identifikace jednoho z modelů identifikace 14 osob**

ID	Záznam byl identifikován jako													
	1201	1202	1205	1206	1207	1208	1212	1428	2200	2201	2204	2205	2212	2421
1201	18	0	0	0	0	0	0	0	0	0	0	0	0	0
1202	1	10	0	0	0	0	0	0	0	0	0	0	0	0
1205	0	0	44	12	4	0	4	0	1	0	6	0	0	7
1206	0	0	1	8	1	1	0	0	0	0	0	0	0	0
1207	0	0	1	3	9	1	0	0	0	0	0	0	0	0
1208	0	0	0	0	0	9	0	0	0	0	0	0	0	0
1212	0	0	0	0	0	0	5	0	0	0	0	0	0	0
1428	0	0	0	0	2	0	0	82	1	0	2	0	0	0
2200	0	0	0	2	0	0	0	0	18	0	3	0	0	0
2201	1	0	0	0	0	0	0	0	0	17	0	0	0	0
2204	0	0	6	0	0	0	0	1	0	0	8	0	0	0
2205	0	0	0	0	0	0	0	0	0	0	0	4	0	0
2212	0	0	0	0	0	0	0	0	0	0	0	0	2	0
2421	0	0	0	0	0	0	2	0	0	0	0	0	0	86

### 6.3.2 Model identifikace 31 osob v populaci 31 osob

Tento model je velmi podobný modelu z předchozí kapitoly. Rozdíl je v počtu osob, je to 31 osob v databázi, které mají více než 5 záznamů. Pro trénování modelu je použito 5 záznamů od každé z osob, pro testování jsou použity všechny zbývající záznamy dané osoby. Model byl opět testován ve 300 realizacích s náhodným výběrem záznamů pro trénování/testování. Výsledky jsou vyhodnoceny obdobným způsobem jako v případě předchozího modelu. Průměrná přesnost identifikace tohoto modelu ve 300 realizacích je 68,80 %. Přesnost je nižší než v předchozím případě jednak z důvodu použití méně záznamů každé osoby pro trénování, a také proto, že existuje více možností zařazení jednotlivého záznamu k osobě. Také se mezi osobami může vyskytovat více osob s podobnými hodnotami příznaků.

### 6.3.3 Model identifikace 14 osob v populaci 100 osob

Pro trénování tohoto modelu je využito 10 náhodně vybraných záznamů od každé ze 14 osob v databázi, které obsahují více než 10 záznamů, a také záznamy od 45 náhodně vybraných ostatních osob, kterým je přiřazeno ID 0. Osoby s ID 0 představují tzv. „zbytek světa“, tedy osoby, které nemají oprávnění přístupu přes biometrický systém. Trénování je provedeno na určitých lidech, testování identifikace „zbytku světa“ probíhá na záznamech od jiných osob. V případě reálného identifikačního systému bychom chtěli zajistit přístup pouze oprávněným osobám. V případě identifikace by probíhalo ověření, zda se jedná o kteroukoli ze 14 oprávněných osob nebo o neoprávněnou osobu – zbytek světa. V systému nemůže být uložena identita všech lidí, ale můžeme systém naučit rozpoznávat neoprávněné osoby na základě dostatečného počtu osob, které nemají přístup do systému. Lze předpokládat, že systém by pak lépe odhalil jako neoprávněné osoby ty osoby, jejichž záznamy byly použity pro trénování. Tento fakt není při testování ověřován. Při testování se ověřuje, zda osoby, které nebyly použity pro trénování, budou

zařazeny do „zbytku světa“ nebo je systém nesprávně identifikuje jako jednu ze 14 oprávněných osob.

Testování probíhalo opět třistakrát s náhodně losovanými záznamy od oprávněných osob a neoprávněnými osobami pro trénování. Hodnocena je správnost zařazení záznamů od oprávněné osoby k dané osobě (stejně jako v předchozích dvou testovacích modelech) a také počet správně zařazených osob ze „zbytku světa“. Průměrné výsledky ze 300 realizací modelu jsou následující. Přesnost identifikace neboli míra správně identifikovaných oprávněných osob je 52,23 %. Přesnost určení ostatních osob jako „zbytku světa“ je 88,91 %. F1 skóre je 0,66.

Výsledky mají podobu tabulky/matice, podobně jako je popsáno v modelu 1. V případě tohoto a následujícího modelu je ovšem o jeden řádek a sloupec více než oprávněných osob. V posledním řádku jsou vypsány počty testovacích vzorků od ostatních osob, které byly přiřazeny k jednotlivým osobám. V posledním sloupci jsou naopak záznamy jednotlivých oprávněných osob, které byly označeny klasifikátorem jako neoprávněné.

**Tabulka 6-4 Výsledky identifikace jednoho z modelů identifikace 14 osob i se „zbytkem světa“**

ID	Záznam byl identifikován jako														
	1201	1202	1205	1206	1207	1208	1212	1428	2200	2201	2204	2205	2212	2421	O
1201	18	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1202	0	6	0	0	0	0	0	0	0	0	0	0	0	0	5
1205	0	0	3	0	0	0	2	0	0	0	1	0	0	2	70
1206	0	0	0	1	0	0	0	0	0	0	0	0	0	0	10
1207	0	0	0	0	5	0	0	0	0	0	0	0	0	0	9
1208	0	0	0	0	0	7	0	0	0	0	0	0	0	0	2
1212	0	0	0	0	0	0	4	0	0	0	0	0	0	0	1
1428	0	0	0	0	0	0	0	60	0	0	0	0	0	0	27
2200	0	0	0	0	0	0	0	0	4	0	0	0	0	0	19
2201	0	0	0	0	0	0	0	0	0	18	0	0	0	0	0
2204	0	0	0	0	1	0	0	0	0	0	4	0	0	0	10
2205	0	0	0	0	0	0	0	0	0	0	0	2	0	0	2
2212	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1
2421	0	0	0	0	0	0	0	0	0	0	0	0	0	64	24
O	1	0	0	0	0	0	1	0	0	8	0	0	1	0	79

Výsledky v tabulce 6-4 ukazují následující skutečnosti. Pokud se jedná o jednu ze 14 osob a systém ji odhalil jako jednu ze 14 osob, je tento údaj ve většině případů správný. V 11 případech z 90 (12,2 %) dochází k nesprávné identifikaci neoprávněné osoby jako oprávněné (viz spodní řádek). Nejčastější chybou je nesprávné zařazení oprávněné osoby jako neoprávněné, jedná se o 45,68 % případů. V praxi by tyto výsledky znamenaly poměrně spolehlivé nepřipouštění neoprávněných osob, ale také poměrně časté nepřipouštění oprávněných osob (45,68 %). Model je nastaven tak, aby bylo méně pravděpodobné připuštění neoprávněné osoby. Pokud by se snížil počet neoprávněných osob pro trénování modelu, zvýšila by se míra připouštění oprávněných i neoprávněných osob.

### **6.3.4 Model identifikace 31 osob v populaci 100 osob**

Tento model je téměř totožný s předchozím modelem, ale místo 14 osob s 10 trénovacími záznamy je pro trénování použito 5 záznamů od každé z 31 osob. Ze zbytku světa se losuje pro trénování opět 45 osob.

Přesnost identifikace oprávněné osoby je 38,51 %. Přesnost zařazení neoprávněné osoby do „zbytku světa“ je 85,75 %. Výsledky jsou méně příznivé než v předchozí model, ale opět je zhoršení očekávané z důvodu menšího počtu trénovacích záznamů jednotlivých oprávněných osob a také z důvodu více možností, mezi kterými se musí systém rozhodovat. F1 skóre je 0,55.

### **6.3.5 Zhodnocení identifikačních modelů**

Použití navržené metody pro identifikaci osob není pro reálný biometrický systém příliš spolehlivé. Podobně jako v případě verifikačních modelů by bylo vhodnější identifikační systém zkombinovat s jinou biometrickou modalitou. Identifikace do určité míry funguje a použití záznamů EKG pro biometrii je jistě možné. V této kombinaci příznaků a klasifikátoru však není rozhodování dostatečně spolehlivé.

## **6.4 Chyby při detekci význačných bodů v signálu**

Jednou z nejdůležitějších součástí navržené metody je detekce význačných bodů v signálu EKG. Algoritmus, který je pro tuto detekci použit, je detekuje velmi přesně. Algoritmus však obsahuje vnitřní chybu, kvůli které detekce u některých záznamů neprobíhá. Jedná se o chybu, kterou není snadné odstranit. Tato chyba se vyskytuje přibližně u 4,8 % záznamů. Tyto záznamy pak nejsou pro trénování a testování použity.

## **6.5 Srovnání dosažených výsledků s jinými autory**

Srovnání výsledků s metodami od jiných autorů je poměrně obtížné. Každý autor využívá jinou databázi, jiný počet testovacích osob a jiné metody testování. Často není v metodách jiných autorů ani blíže specifikován způsob testování. Přesto zde jsou uvedeny výsledky navržené metody v porovnání s ostatními a je zde diskutována jejich srovnatelnost.

### **6.5.1 Srovnání výsledků verifikace**

Finální výsledky verifikace pomocí navržené metody jsou FAR 3,81 % a FRR 15,75 %. Výsledky verifikace metody uvedené v kapitole 3.1 jsou FAR 0,6 %, FRR 0,58 %. Verifikace probíhala na databázi 80 osob, přičemž pro trénování a testování byla použita jiná část stejného záznamu EKG. Testování na záznamech, které byly naměřeny separátně od trénovacích záznamech (tak jak bylo provedeno v této práci), je náročnější, protože mezi záznamy je větší možná variabilita.

Metoda popsaná v kapitole 3.6 vykazuje přesnost verifikace 20 osob 95 %. Jedná se o celkovou přesnost verifikace. Výsledky této metody jsou s navrženou metodou srovnatelné. Navržená metoda navíc prováděla verifikaci ve větším vzorku dat (100 osob), podmínky testování byly tedy opět náročnější v této práci.

Výsledky metody z kapitoly 3.7 jsou FRR 3%, FAR 2,5 % na datech od 74 osob. Tyto výsledky jsou lepší v porovnání s navrženou metodou. Metoda představená v kapitole 3.8 má výsledky verifikace 14 osob FRR 0,02 % a FAR 1,94 %. Výsledky jsou lepší než navržená metoda, ovšem testování probíhalo na výrazně menší databázi.

### **6.5.2 Srovnání výsledků identifikace**

Při identifikaci 14 osob dosáhla navržená metoda přesnosti 81,46 %, při identifikaci 31 osob přesnosti 68,80 %. Po přidání 84 (respektive 69) osob ze „zbytku světa“ je přesnost identifikace 52,23 %, respektive 38,51 %. TRR je 88,91 %, respektive 85,75 %.

Metoda z kapitoly 3.2 dosáhla přesnosti identifikace 95% v databázi 25 osob, metoda v kapitole 3.3 dosáhla přesnosti 98 % v databázi 25 osob. V metodě představené v kapitole 3.4 bylo dosaženo přesnosti 98 % na databázi 29 osob (byly použity stejné záznamy pro trénování a testování). Kapitola 3.5 dosáhla přesnosti 93,8 % na databázi 10 osob. Metoda z kapitoly 3.9 dosáhla přesnosti 95,7 % při identifikaci 45 osob (byly použity stejné záznamy pro trénování a testování).

Oproti ostatním metodám byly při zde představeném testování záznamy měřeny pomocí chytrých hodinek a ne pomocí ověřeného lékařského EKG přístroje, což výrazně snižuje kvalitu měřených signálů. Pro trénování a testování jsou zde používány různé záznamy, v některých metodách byl použit stejný záznam pro trénování a testování, přičemž byl daný záznam rozdělen na trénovací a testovací úsek.

Celkově dosahuje navržená metoda spíše horších výsledků identifikace než ostatní představené metody. Co se týče verifikace, jsou výsledky poměrně dobré, srovnatelné s některými metodami. Pro praktické využití této metody by byla vhodná kombinace s jinou biometrickou modalitou pro dosažení vysoké přesnosti a bezpečnosti proti falsifikaci.



## 7. ANALÝZA VERIFIKAČNÍHO PROCESU

Při úvaze o tom, v čem je EKG pro každého člověka tak specifické, že ho lze použít pro identifikaci nebo verifikaci, se můžeme zamýšlet nad tím, která část signálu EKG je tak specifická? Jde o nějakou konkrétní část srdce, která je u každé osoby rozdílná? Je tedy některý příznak natolik důležitý, že se podle něj klasifikátor vždy rozhoduje? Jistě jde o kombinaci příznaků, ale dá se najít nějaká obecná zákonitost pro odlišení jedné osoby od ostatních?

Tato kapitola nejprve shrnuje poznatky týkající se jednotlivých použitých příznaků a jejich interpretaci. V další části je popsána analýza důležitosti příznaků při verifikaci jednotlivých osob a jsou z ní odvozeny obecné závěry.

### 7.1 Anatomicko-fyziologická interpretace příznaků

V této kapitole je pro jednotlivé příznaky popsán jejich anatomicko-fyziologický základ a vysvětleno co ovlivňuje jejich hodnotu. Fyziologii srdce se věnuje kapitola 2.1, při úvahách o interpretaci příznaků byly použity informace v ní obsažené. Veškeré číselné hodnoty rychlostí převodu vzruchu a časových intervalů, které jsou v této kapitole uvedeny, jsou fyziologické hodnoty, skutečná hodnota těchto veličin může být u jednotlivců i mimo toto rozmezí. Zdroje těchto hodnot jsou uvedeny u příslušných témat v teoretické kapitole 2.1, z níž tato kapitola čerpá informace. Tyto hodnoty se v různých literárních zdrojích liší, ale jsou zde uvedeny pro přibližnou představu.

#### 7.1.1 Intervalové příznaky

**Intervaly QR a RS**, respektive čas od začátku komplexu QRS po kmit R a od kmitu R do konce komplexu QRS jsou dohromady časem trvání komplexu QRS. Je to čas potřebný pro postup depolarizace komor od Hisova svazku, Tawarovými raménky (rychlost převodu 1-1,5 m/s), a dále Purkyňovými vlásky (3-3,5 m/s). Od převodního systému srdečního se vzruch šíří také samotnou svalovinou komor (rychlost převodu přibližně 0,4 m/s [26]). Doba trvání komplexu QRS je tedy ovlivněna rychlostí převodu jednotlivými částmi srdce a velikostí srdečních komor (vzdáleností, kterou musí vzruch v jednotlivých částech urazit), tloušťkou srdeční stěny, patologickými jevy (např. jizvy po infarktu mění vodivost tkáně nebo cestu šíření vzruchu), tvarem srdce.

Velikost a tvar srdce, stejně jako rychlosti převodu, mohou být u každého jednotlivce rozdílné, v závislosti na velikosti jejich těla či srdce samotného, na fyzické kondici a případných patologiích. Celková délka komplexu QRS se pohybuje v rozmezí 80 - 100 ms.

Přesná interpretace polohy kmitu R v rámci QRS komplexu je velmi komplexním problémem, souvisí s mnoha (již výše uvedenými) faktory a také s převodem vzruchu mezi endokardem a epikardem srdečních komor. Záleží také na poloze elektrod daného svodu.

**Interval ST<sub>offset</sub>** odpovídá času od konce komplexu QRS po konec vlny T. Část před začátkem vlny T se běžně nazývá jako úsek ST (nejedná se o intervalový příznak ST, ale konvenčně nazývaný ST úsek nebo ST segment), jedná se o období stabilní aktivity srdce (fáze plató), EKG je v tomto úseku na izolínii. Délka ST úseku závisí na délce fáze plató buněk srdečních komor, u jednotlivců se může mírně lišit. Vlna T odpovídá postupné

repolarizaci buněk srdečních komor, opět závisí na délce fáze plató jednotlivých buněk. Závisí také na velikosti a tvaru srdce. Intervalový příznak  $ST_{\text{offset}}$  je silně závislý na srdeční frekvenci. Při vyšší srdeční frekvenci je kratší doba trvání fáze plató, protože je zvýšena rychlost průchodů vápenatých iontů působením autonomních neuronů. Délka intervalu je tedy u jednotlivých cyklů jedince rozdílná v závislosti na tepové frekvenci, čemuž je nutné zabránit, protože je potřebné, aby byly příznaky pro daného člověka charakteristické. Proto je délka intervalu  $ST_{\text{offset}}$  normalizována – dělena délkou celého srdečního cyklu (intervalem  $P_{\text{onset}}T_{\text{offset}}$ ), což zajistí alespoň do určité míry nezávislost příznaku na tepové frekvenci.

**Délka vlny P** je určena rychlostí postupu depolarizační vlny svalovinou síní, tedy až do nejbližší buňky svaloviny síní od SA uzlu. Je tedy dána rychlostí převodu impulzu z SA uzlu (pohybuje se v rozmezí 0,8 - 1 m/s) do celé svaloviny síní, a také velikostí a tvarem síní, popřípadě patologiemi v převodu vzruchu síněmi. Rychlost převodu je ovlivňována působením autonomních neuronů, které ovlivňují srdeční frekvenci. Stejně jako předchozí příznak je délka vlny normalizována délkou celého srdečního cyklu, aby se zanedbal vliv změn frekvence na délku tohoto intervalu.

**Interval  $P_{\text{offset}}Q$** , tedy čas od konce vlny P po začátek komplexu QRS, je dán rychlostí převodu vzruchu AV uzlem. Tento převod pomalý, aby došlo ke kontrakci síní v dostatečném předstihu před kontrakcí komor, aby došlo k efektivnímu pumpování krve. Rychlost převodu, a tedy délka tohoto intervalu je závislá na srdeční frekvenci, je opět řízena autonomními neurony, tento příznak proto musí být opět normalizován délkou celého cyklu. Pro jednotlivé osoby je charakteristická jednak dráha, kterou musí vzruch urazit buňkami AV uzlu, kde je převod pomalý (rychlost přibližně 0,05 m/s), a také samotnou rychlostí převodu, která je jistě také charakteristická.

Ostatní intervalové příznaky jsou získány jako součet určité kombinace předchozích pěti uvedených intervalů, případně jejich částí. U některých příznaků (například PQ a  $P_{\text{onset}}Q$ , resp. ST a  $ST_{\text{offset}}$ ) je rozdíl v čase od počátku vlny po vrchol vlny, respektive v čase od vrcholu vlny po konec vlny. Vrchol vlny vždy odpovídá okamžiku, kdy je depolarizační/repolarizační vlna v daném směru nejintenzivnější, postupuje nejrychleji nebo v největším objemu buněk. Tento okamžik může být v rámci jednotlivých vln pro jednotlivé osoby charakteristicky posunut do jiné fáze této vlny na základě tvaru srdce a rychlosti převodu srdečních buněk.

## 7.1.2 Amplitudové příznaky

Rozdíl mezi kmitem R a vrcholem jiné vlny může být ovlivněn jednak amplitudou kmitu R a také amplitudou té dané vlny. Amplituda komplexu QRS se do tohoto rozdílu promítne vždy výrazněji než jiná vlna, protože odpovídá depolarizaci největší masy srdečních buněk a její odezva je tedy nejsilnější.

Amplituda jednotlivých vln je absolutní hodnotou vzdálenosti od izolinie, nejedná se o relativní hodnotu vzhledem k síle signálu. Proto bude velikost amplitud, a tedy i jejich rozdíl, ovlivněna nejen množstvím a silou signálu vycházejícího z jednotlivých buněk, ale také kvalitou snímání, tedy útlumem signálu ve tkáni a kůži, vodivostí přechodu kůže-elektroda a citlivostí měřicí techniky. Citlivost měřicí techniky předpokládáme u všech měření v rámci databáze shodnou, protože byl použit stejný měřicí přístroj. Vodivost tkání a přechodu kůže-elektroda je ovlivněna jednak stálou skladbou tkání, ale také je ovlivněna momentálním rozpořádáním měřené osoby. Obzvláště vodivost spojení kůže-

elektroda je momentálním rozpořčením ovlivněna silně, velkou roli zde hraje vlhkost kůže na spojení s elektrodou.

Čistě z hlediska elektrické aktivity srdečních buněk je amplituda vlny P dána velikostí elektrického vzruchu jednotlivých buněk, počtem buněk síní (velikostí síní) a rychlostí postupu vzruchu síněmi. Při hypertrofii síní a rychlejším vedení vzruchu bude amplituda vlny P vyšší. Nutno dodat, že u některých osob EKG neobsahuje vlnu P z důvodu některých patologií. Kmit R je z hlediska srdeční aktivity větší, když je větší hmota svaloviny komor, dále ji zvětšuje velikost vzruchu jednotlivých buněk a rychlost vedení vzruchu. Amplituda vlny T je ovlivněna rychlostí a mírou repolarizace komor a velikostí komor.

### **7.1.3 Úhlové příznaky**

Úhlové příznaky kombinují amplitudové a intervalové příznaky, jejich vzájemná kombinace by mohla teoreticky být přínosná, přinášet novou charakteristickou informaci. Z této práce však byly vyřazeny (viz kapitola 5.1.3), tato informace nebyla dostatečně přínosná.


### **7.1.4 Příznaky variability intervalů**

V rámci úvahy o možných charakteristických rysech EKG byla vznesena hypotéza, že někteří lidé mohou mít stabilní tepovou frekvenci, zatímco jiní lidé ji mají více proměnnou v čase. Proto byl navržen příznak variability RR intervalů. Podobně i jiné intervaly by mohly být časově proměnné u některých osob více než u jiných. Mohlo by to svědčit o různé dynamičnosti srdeční činnosti u jednotlivých lidí. Na základě analýzy byla většina těchto příznaků vyřazena, ale jeden (variabilita intervalů PR) byl v metodě zachován, protože je u jednotlivých osob více proměnný v čase. Někteří jedinci tedy mají stabilní aktivitu srdečních síní, jiní ji mají v čase relativně více proměnlivou.

## **7.2 Hledání spojitosti mezi hodnotami příznaků a věkem a hmotností osob**


Ve světle předchozí kapitoly by mohlo člověka napadnout, zda některý z příznaků, který je teoreticky ovlivněn i velikostí srdce, bude vyšší u osob s vyšší hmotností. Proto bylo provedeno srovnání hodnot jednotlivých příznaků jednotlivých osob a hledání spojitosti mezi příznakem a hmotností, popřípadě věkem jednotlivých osob.

Analýza probíhala graficky pomocí korelačních diagramů – 2D grafů s hodnotami hmotnosti/věku na ose x a hodnotami jednotlivých příznaků v záznamech na ose y. Ve většině příznaků nebyla nalezena významná spojitost mezi hmotností nebo věkem a hodnotou daného příznaku. Pro příklad grafu bez významné analýzy je zde uveden korelační diagram hmotnosti osob s hodnotami příznaku obr. 7.1. V diagramech bylo také odlišeno, zda se jedná o hodnotu příznaku v záznamu EKG od muže nebo ženy, aby se odhalila případná závislost pouze u jednoho pohlaví. Taková závislost se však v měřených datech nevyskytuje.



**Obrázek 7.1 Korelační diagram hmotnosti a hodnoty příznaku délky vlny P, modře jsou vyznačeny hodnoty příznaku mužů, červeně žen. Není zde žádná závislost hodnoty příznaku na hmotnosti měřené osoby**

U dvou příznaků, konkrétně se jedná o oba použité amplitudové příznaky (amplituda RP a amplituda RT) se vyskytuje určitá závislost mezi hodnotou příznaku a hmotností osob, přičemž s hmotností roste hodnota příznaku. (viz obr. 7.2) Diagramy obsahují regresní přímku jednoduché lineární regrese dat. Tato lineární závislost není striktně platná pro všechny záznamy a všechny osoby. Můžeme zde však vidět jistou závislost. Velikost rozdílu mezi vrcholem kmitu R a vrcholem jiné vlny je tedy obecně větší u osob s vyšší hmotností.




**Obrázek 7.2 Korelační diagramy hmotnosti a hodnoty amplitudových příznaků**

### 7.3 Srovnání důležitosti a přínosu příznaků pro verifikaci osob

V této kapitole je analyzována otázka, zda jsou některé příznaky důležitější než ostatní příznaky. Je například jeden příznak tak charakteristický, že je při rozhodování o identitě osoby téměř vždy použit? Nebo je použit výrazně častěji než jiné příznaky?

Klasifikátor typu náhodný les provádí klasifikaci pomocí rozdělování příznakového prostoru vždy na dva podprostory, v každém uzlu na základě jedné proměnné a jednoho prahu (viz kapitola 4.3.2). Z již natrénovaného náhodného lesa je možné pro každý příznak určit, v kolika uzlech byl příznakový prostor rozdělen podle daného příznaku. Pokud tedy existuje příznak, který je pro rozhodování o klasifikaci důležitější než ostatní, bude mít tento příznak větší skóre počtu rozdělení v uzlech než ostatní příznaky. Pokud bude skóre u všech příznaků podobné, bude jejich důležitost srovnatelná. Při aplikaci na verifikaci pomocí EKG tato analýza ukáže, zda je některá část EKG důležitější pro rozpoznávání osob než jiné části nebo vlastnosti EKG.


V následující části jsou uvedeny sloupcové grafy počtu rozdělení příznakového prostoru podle jednotlivých příznaků u verifikačních modelů totožných jako při testování v kapitole 6.2. Klasifikátorem je vždy náhodný les o 40 náhodných stromech, každý model je natrénován a otestován třistakrát, pokaždé s jiným náhodně vybraným trénovacím a testovacím souborem záznamů (jiné osoby pro trénování a testování, jiné záznamy od verifikované osoby). Každý sloupcový graf přísluší modelu (tedy souboru 300 modelů) jedné osoby.



Obrázek 7.3 Váha jednotlivých příznaků osob 1201 a 1202


Při verifikaci osoby 1201 byl příznakový prostor rozdělen podle intervalu RS výrazně častěji oproti ostatním příznakům. Mezi další nadprůměrné příznaky patří zejména interval  $P_{\text{offset}}R$  a amplituda RP, které mají více než 1000 rozdělení. Mezi další silnější příznaky patří intervaly QR, PR,  $P_{\text{offset}}Q$  a amplituda RT.

V případě osoby 1202 není žádný příznak výrazně silnější než ostatní. Mezi silnější příznaky patří intervaly QR, RT,  $P_{\text{offset}}Q$ , PT, dále oba amplitudové příznaky a příznak variability intervalu PR. Příznak interval RS, který byl tak významný pro verifikaci osoby 1201, je pro osobu 1202 podprůměrným, slabým příznakem.




**Obrázek 7.5** Váha jednotlivých příznaků osob 1205 a 1206

Osoby 1205 a 1206 mají poměrně rovnoměrně rozloženou váhu příznaků. Mezi silnější příznaky osoby 1205 patří interval  $QT_{\text{offset}}$  a oba amplitudové příznaky, u osoby 1206 jsou to interval ST a amplituda RP.



**Obrázek 7.4** Váha jednotlivých příznaků osob 1207 a 1208


Osoba 1207 má velkou váhu na intervalu  $QT_{\text{offset}}$ , silná je také délka vlny P a amplituda RP. Osoba 1208 má největší váhu na příznaku  $P_{\text{onsetQ}}$ , silné jsou i oba amplitudové příznaky a intervaly RT,  $ST_{\text{offset}}$  a délka vlny P.



**Obrázek 7.6** Váha jednotlivých příznaků osob 1212 a 1428


Osoba 1212 má jeden velmi charakteristický příznak – interval QR, který má velkou váhu, pro rozdělení příznakového prostoru je použit nejméně třikrát častěji než kterýkoli jiný příznak. Z ostatních příznaků mezi silnější patří intervaly  $P_{offset}R$ ,  $ST_{offset}$ , ST a RS.

Osoba 1428 nemá žádný příliš silný příznak, mezi silnější patří intervaly  $QT_{offset}$ ,  $P_{offset}Q$  a PT.




**Obrázek 7.7** Váha jednotlivých příznaků osob 2200 a 2201

Osoba 2200 nemá žádný výrazně silnější příznak, větší váhu oproti ostatním mají intervaly RS, ST a amplituda RP. Naopak osoba 2201 má velmi silné oba amplitudové příznaky, další silné příznaky jsou intervaly QR, RS a  $P_{offset}R$ .



Obrázek 7.8 Váha jednotlivých příznaků osob 2204 a 2205

Osoba 2204 nemá žádný výrazně silný příznak. Osoba 2205 má jeden velmi silný příznak – interval  $QT_{offset}$ , mezi další silné příznaky patří intervaly RS a ST a oba amplitudové příznaky.



Obrázek 7.9 Váha jednotlivých příznaků osob 2212 a 2421

Osoba 2212 má čtyři silné příznaky – oba amplitudové příznaky a intervaly  $QT_{offset}$  a ST. Osoba 2421 má jeden silnější příznak – interval RT, silné jsou také amplituda RP a variabilita intervalu PR.

Obecně se z této analýzy dá vyvodit několik závěrů. Neexistuje příznak, který by byl nejdůležitější pro verifikaci všech osob. Jednotlivé osoby mají některé příznaky velmi silné oproti ostatním, přičemž u různých osob se jedná o různé příznaky, které jsou pro danou osobu charakteristické. Některé osoby nemají žádný výrazně nejsilnější příznak. U jednotlivých osob lze také určit příznaky, které nejsou výrazně silnější, ale mají o něco vyšší váhu než ostatní příznaky.

Co se týče důležitosti jednotlivých příznaků u různých osob, lze v testovaných datech určit, zda jsou některé příznaky výrazně silnější nebo silnější pro více osob. Interval  $QT_{offset}$  je výrazně silnější oproti ostatním příznakům u 3 osob ze 14, u dvou osob patří k silnějším příznakům. Amplituda RP je výrazně silnější u 2 osob a patří k silnějším příznakům u 8 osob. To znamená, že ze 14 osob je tento příznak nadprůměrně silný



u 10 osob. Amplituda RT je výrazně silnější u 2 osob, silnější u 4 osob. Intervaly RS a ST jsou oba výrazně silnější vždy u jedné osoby, silnější u 4 osob. Pro tři různé osoby jsou nadprůměrně silné také intervaly QR, RT a  $P_{\text{offset}}R$ . Ostatní příznaky byly silnější jen u dvou a méně osob.

Pokud bychom chtěli vybrat některé obecně silnější příznaky u různých osob, šlo by o interval  $QT_{\text{offset}}$ , amplitudy RP a RT a intervaly RS a ST. Jedná se tedy především o příznaky spojené s časem a amplitudou komplexu QRS a vlny T. Intervaly spojené s vlnou P mají relativně menší důležitost. Ovšem vzhledem k tomu, že s vlnou P souvisí 9 ze 14 příznaků, je důležitost vlny P ve skutečnosti také vysoká. Nelze tedy říci, že by některá část EKG byla obecně důležitější pro verifikaci než ostatní části.

# ZÁVĚR

V této diplomové práci je v teoretické části shrnuto devět existujících publikovaných metod pro identifikaci nebo verifikaci osob pomocí EKG. Také jsou zde popsány informace týkající se biometrie, elektrofyzologie srdce a EKG. Hlavní částí této práce je metoda pro extrakci 33 příznaků ze záznamů EKG a jejich testování, dále kombinace kvalitních příznaků pro verifikaci a identifikaci a testování verifikačních a identifikačních modelů. Přínosem této práce je také interpretace a zhodnocení důležitosti extrahovaných příznaků. V rámci této práce bylo rovněž naměřeno 288 záznamů EKG od 18 osob pomocí Apple Watch 4.

Navržená metoda pro extrakci příznaků se inspiroje hlavně ve třech existujících metodách, ale jsou zde i vlastní příznaky. Extrahované příznaky jsou rozděleny do čtyř skupin – intervalové, amplitudové, úhlové a příznaky variability intervalů a amplitud. Na základě analýzy interpersonální variability příznaků, vzájemné podobnosti příznaků a na základě zpětné selekce příznaků byly z celkových 15 navržených intervalových příznaků odstraněny 2 příznaky. Ze 4 amplitudových příznaků byly vyřazeny 2 příznaky, ze 3 úhlových příznaků byly vyřazeny všechny, ze 11 příznaků variability intervalů a amplitud jich bylo 10 vyřazeno. Tím pro další použití pro verifikaci zůstalo 16 příznaků.

Na záznamech EKG z databáze z PhysioNetu a na vlastní databázi rozšířené o další záznamy byla otestována metoda verifikace osob na základě 16 extrahovaných příznaků a s použitím náhodného lesa jako klasifikátoru. Průměrné výsledky verifikace 14 osob z vlastní databáze dat jsou TRR 96,19 %, TAR 84,25. Tyto výsledky jsou vzhledem k použitému měření pomocí chytrých hodinek, použití záznamů měřených v rozdílných časech pro trénování a testování a také k množství záznamů v databázi dobré a srovnatelné s výsledky jiných metod. Identifikace 14 osob pomocí navržených příznaků a náhodného lesa má přesnost 81,46 %, která je vzhledem k nízkému počtu osob poměrně nízká. Testování identifikace 14 osob v databázi 100 osob, kdy je identifikační model natrénován pro rozpoznání a připuštění 14 konkrétních osob a ostatní osoby má odmítnout, je přesnost identifikace oprávněných osob pouze 52,23 %, z ostatních osob je však 88,91 % zařazeno správně mezi neoprávněné osoby.

Z analýzy důležitosti příznaků vyplývá, že pro jednotlivé osoby jsou při rozhodovacím verifikačním procesu důležitější různé části signálu EKG. Některé osoby mají jeden či několik velmi silných, charakteristických příznaků, které je odlišují od ostatních osob, jiné osoby mají jiné charakteristické příznaky, některé osoby nemají žádný silnější příznak a jednotlivé příznaky se při rozhodování projevují rovnoměrně. Pokud bychom chtěli vybrat některé obecně silnější příznaky u různých osob, šlo by o interval  $QT_{offset}$ , amplitudy RP a RT a intervaly RS a ST.

Přestože jsou výsledky verifikace pomocí navržené metody srovnatelné s ostatními metodami, pro aplikaci v reálném verifikačním systému by bylo potřebné pro zajištění dostatečné přesnosti systému zkombinovat záznam EKG s jinou spolehlivou biometrickou modalitou, například s otisky prstu nebo skenem duhovky. Otisk prstu nebo sken duhovky je určitým způsobem možné falsifikovat a dosáhnout tak neoprávněného přístupu. Záznam EKG se dá falsifikovat jen velmi obtížně, a proto může být jeho použití velmi přínosné. Kombinací identifikace pomocí jiné modality a následné verifikace pomocí záznamu EKG by mohl vzniknout velmi efektivní a bezpečný biometrický systém.

# Literatura

- [1] N. Belgacem, A. Nait-Ali, R. Fournier, a F. Bereksi-Reguig, „ECG Based Human Authentication using Wavelets and Random Forests", *Int. J. Cryptogr. Inf. Secur.*, roč. 2, č. 2, s. 1–11, čer. 2012, doi: 10.5121/ijcis.2012.2201.
- [2] Y. N. Singh a P. Gupta, „ECG to Individual Identification", in *2008 IEEE Second International Conference on Biometrics: Theory, Applications and Systems*, 2008, s. 1–8. doi: 10.1109/BTAS.2008.4699343.
- [3] A. K. Jain, A. Ross, a S. Prabhakar, „An Introduction to Biometric Recognition", *IEEE Trans. Circuits Syst. Video Technol.*, roč. 14, č. 1, s. 4–20, 2004, doi: 10.1109/TCSVT.2003.818349.
- [4] P. Melin, D. Romero, F. Valdez, a J. V. Herrera-Rivera, „Optimization of Neural Networks for the Identification of Persons using Images of the Human Ear as a Biometric Measure", *Eng. Lett.*, roč. 20, č. 1, s. 94–100, bře. 2012.
- [5] Y. Liu, J. Guo, P. Liu, J. Lee, a C. Yao, „Panoramic Face Recognition", *IEEE Trans. Circuits Syst. Video Technol.*, roč. 28, č. 8, s. 1864–1874, srp. 2018, doi: 10.1109/TCSVT.2017.2693682.
- [6] W. Yang, S. Wang, J. Hu, G. Zheng, a C. Valli, „Security and Accuracy of Fingerprint-Based Biometrics: A Review", *Symmetry* 20738994, roč. 11, č. 2, s. 141, úno. 2019, doi: 10.3390/sym11020141.
- [7] A. Nigam, Lovish, A. Bendale, a P. Gupta, „Efficient Iris Recognition System Using Relational Measures", in *Computational Forensics*, Cham, 2015, s. 55–66. doi: 10.1007/978-3-319-20125-2\_6.
- [8] Stefan SILBERNAGL, *Atlas fyziologie člověka*, 1. vyd. Praha: Avicenum, 1984.
- [9] Miloš Langmeier, *Základy lékařské fyziologie*, 1. vyd. Praha: Grada, 2009.
- [10] Jindřich Mourek, *Fyziologie: učebnice pro studenty zdravotnických oborů*. Praha: Grada, 2012.
- [11] Leif Sörnmo a Pablo Laguna, *Bioelectrical Signal Processing in Cardiac and Neurological Applications*. Elsevier, 2005. Viděno: bře. 15, 2021. [Online]. Dostupné z: [https://app.knovel.com/web/toc.v/cid:kpBSPCNA02/viewerType:toc//root\\_slug:viewerType%3Atoc/url\\_slug:root\\_slug%3Abioelectrical-signal?kpromoter=federation&hierarchy=kt00BY5DM3%2Bkt00BY5DN5](https://app.knovel.com/web/toc.v/cid:kpBSPCNA02/viewerType:toc//root_slug:viewerType%3Atoc/url_slug:root_slug%3Abioelectrical-signal?kpromoter=federation&hierarchy=kt00BY5DM3%2Bkt00BY5DN5)
- [12] L. Ivanciu, P. Farago, a S. Hintea, „A REVIEW OF ECG BASED BIOMETRIC SYSTEMS", *Acta Tech. Napoc. Electron. - Telecomunicatii Cluj-Napoca*, roč. 59, č. 4, s. 1–4, 2018.
- [13] L. Biel, O. Pettersson, L. Philipson, a P. Wide, „ECG analysis: a new approach in human identification", *IEEE Trans. Instrum. Meas.*, roč. 50, č. 3, s. 808–812, čer. 2001, doi: 10.1109/19.930458.
- [14] J. Pan a W. J. Tompkins, „A Real-Time QRS Detection Algorithm", *IEEE Trans. Biomed. Eng.*, roč. BME-32, č. 3, s. 230–236, bře. 1985, doi: 10.1109/TBME.1985.325532.
- [15] S. A. Israel, J. M. Irvine, A. Cheng, M. D. Wiederhold, a B. K. Wiederhold, „ECG to identify individuals", *Pattern Recognit.*, roč. 38, č. 1, s. 133–142, led. 2005, doi: 10.1016/j.patcog.2004.05.014.
- [16] S. Hadiyoso, S. Aulia, a A. Rizal, „One-Lead Electrocardiogram for Biometric Authentication using Time Series Analysis and Support Vector Machine", *Int. J.*

- Adv. Comput. Sci. Appl. Ijacs*, roč. 10, č. 2, Art. č. 2, pro. 2019, doi: 10.14569/IJACSA.2019.0100237.
- [17] T.-W. Shen, „Biometric identity verification based on electrocardiogram (ECG)", Dissertation thesis, The University of Wisconsin-Madison, Madison, 2005. [Online]. Dostupné z: <https://search.proquest.com/openview/f215efe040139b0d1c9c1a5425a03956/1?cbl=18750&diss=y&pq-origsite=gscholar>
  - [18] G. Wübbeler, M. Stavridis, D. Kreiseler, R.-D. Bousseljot, a C. Elster, „Verification of humans using the electrocardiogram", *Pattern Recognit. Lett.*, roč. 28, č. 10, s. 1172–1175, čvc. 2007, doi: 10.1016/j.patrec.2007.01.014.
  - [19] K. N. Plataniotis, D. Hatzinakos, a J. K. M. Lee, „ECG Biometric Recognition Without Fiducial Detection", in *2006 Biometrics Symposium: Special Session on Research at the Biometric Consortium Conference*, zář. 2006, s. 1–6. doi: 10.1109/BCC.2006.4341628.
  - [20] C. Chiu, C. Chuang, a C. Hsu, „A Novel Personal Identity Verification Approach Using a Discrete Wavelet Transform of the ECG Signal", in *2008 International Conference on Multimedia and Ubiquitous Engineering (mue 2008)*, dub. 2008, s. 201–206. doi: 10.1109/MUE.2008.67.
  - [21] T. Lugovaya, „The ECG-ID Database". *physionet.org*, 2011. doi: 10.13026/C2J01F.
  - [22] L. Smital, M. Vitek, J. Kozumplik, a I. Provazník, „Adaptive Wavelet Wiener Filtering of ECG Signals", *IEEE Trans. Biomed. Eng.*, roč. 60, č. 2, s. 437–445, úno. 2013, doi: 10.1109/TBME.2012.2228482.
  - [23] M. Vitek, J. Hrubeš, a J. Kozumplik, „A wavelet-based ECG delineation with improved P wave offset detection accuracy", in *Proceedings of Biosignal 2010: Analysis of Biomedical Signals and Images.*, Brno, Czech Republic, 2010, s. 160–165.
  - [24] G. G. Moisen, „Classification and Regression Trees", in *Encyclopedia of Ecology*, S. E. Jørgensen a B. D. Fath, Ed. Oxford: Academic Press, 2008, s. 582–588. doi: 10.1016/B978-008045405-4.00149-X.
  - [25] Y. Liu, Y. Wang, a J. Zhang, „New Machine Learning Algorithm: Random Forest", in *Information Computing and Applications*, Berlin, Heidelberg, 2012, s. 246–252. doi: 10.1007/978-3-642-34062-8\_32.
  - [26] J. B. Kleyn M.D. a R. M. F. Houtappel M.D, „On the measurement of the QRS complex and the interpretation thereof by direct and indirect deduction", *Am. Heart J.*, roč. 37, č. 5, s. 806–810, dub. 1949, doi: 10.1016/0002-8703(49)90178-7.